


UNIVERSIDADE FEDERAL DO PARANÁ

IASMIN FERNANDA PORTELA PFUTZ

MODELAGEM GEOESTATÍSTICA ASSOCIADA À VARIÁVEIS
DENDROMÉTRICAS E DE SENSORIAMENTO REMOTO PARA PREDIÇÃO
ESPACIAL EM POVOAMENTO DE *Tectona grandis* L. f.

CURITIBA

2020



IASMIN FERNANDA PORTELA PFUTZ

MODELAGEM GEOESTATÍSTICA ASSOCIADA À VARIÁVEIS
DENDROMÉTRICAS E DE SENSORIAMENTO REMOTO PARA PREDIÇÃO
ESPACIAL DE POVOAMENTO DE *Tectona grandis* L. f.

Dissertação apresentada ao Curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia Florestal.

Orientador: Prof. Dr. Allan Libanio Pelissari

Coorientadora: Prof^a. Dr^a. Ana Paula Dalla Corte

Coorientador: Prof. Dr. Sidney Fernando Caldeira

CURITIBA

2020

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Pfutz, Iasmin Fernanda Portela

Modelagem geoestatística associada à variáveis dendrométricas e de sensoriamento remoto para predição espacial em povoamento de *Tectona grandis* L. f. / Iasmin Fernanda Portela Pfutz. - Curitiba, 2020.

82 f. : il.

Orientador: Prof. Dr. Allan Libanio Pelissari

Coorientadores: Profa. Dra. Ana Paula Dalla Corte

Prof. Dr. Sidney Fernando Caldeira

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 17/02/2020.

Área de concentração: Manejo Florestal.

1. Florestas - Métodos estatísticos. 2. Dendrometria. 3. Sensoriamento remoto. 4. Teca (Árvore). 5. Teses. I. Pelissari, Allan Libanio. II. Dalla Corte, Ana Paula. III. Caldeira, Sidney Fernando. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V. Título.

CDD – 634.9

CDU – 634.0.51

Bibliotecária: Berenice Rodrigues Ferreira – CRB 9/1160



MINISTÉRIO DA EDUCAÇÃO
SETOR DE CIÊNCIAS AGRÁRIAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
FLORESTAL - 40001016015P0

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da dissertação de Mestrado de **IASMIN FERNANDA PORTELA PFUTZ** intitulada: **MODELAGEM GEOESTATÍSTICA ASSOCIADA À VARIÁVEIS DENDROMÉTRICAS E DE SENSORIAMENTO REMOTO PARA PREDIÇÃO ESPACIAL EM POVOAMENTO DE *Tectona grandis* L. f.**, sob orientação do Prof. Dr. ALLAN LIBANIO PELISSARI, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 17 de Fevereiro de 2020.

ALLAN LIBANIO PELISSARI

Presidente da Banca Examinadora (UNIVERSIDADE FEDERAL DO PARANÁ)

ANGELO AUGUSTO EBLING

Avaliador Externo (UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA)

CARLA KRULIKOWSKI RODRIGUES PELISSARI

Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ)

Aos meus queridos avós Cida, Alfredo e Mercedes (in memoriam)

Aos meus pais Acir e Berenice

Com todo meu amor e gratidão

Dedico.

AGRADECIMENTOS

À DEUS por todas as benções que já recebi.

À UFPR e ao Programa de Pós-Graduação em Engenharia Florestal pela oportunidade de realização do curso.

Ao meu orientador Prof. Dr. Allan L. Pelissari, pela paciência, confiança orientação e ensinamentos transmitidos.

Aos coorientadores: Prof^ª. Dr^ª. Ana Paula Dalla Corte e Prof. Dr. Sidney Fernando Caldeira, pela disponibilidade e contribuições neste trabalho.

Aos meus pais, Acir e Berenice, meus maiores exemplos de vida, pelo amor incondicional, apoio e confiança sempre demonstrados comigo.

À família Portela e Pfutz, pelo apoio, incentivo e amor.

Aos amigos de pós-graduação: Aline, Ana Paula, Adriane, Bruna, Franciel, Gabriel, Iací, Manu, Marks, Thiago e Verônica, pela convivência e amizade. E aos demais colegas do BIOFIX.

As minhas queridas amigas: Eduarda, Fernanda, Isabela e Mariana, que mesmo longe sempre estiveram presente e são essenciais na minha vida.

A todos, que de alguma forma contribuíram para a realização deste trabalho, minha eterna gratidão. Muito Obrigada!

A verdadeira coragem é ir atrás de seus sonhos mesmo quando todos dizem
que ele é impossível (Cora Coralina).

RESUMO

A teca é uma espécie de alto valor para plantios florestais para a produção sustentável da indústria de base florestal brasileira ao mesmo tempo que reduz a pressão da exploração de florestas nativas. Para o desenvolvimento de planos de manejo em bases sustentáveis, é necessário o conhecimento detalhado e adequado de suas variáveis obtidas a partir de inventários florestais. Nesse sentido, a geoestatística tem sido testada e aplicada para direcionar a condução dos plantios de teca. Contudo, tem-se verificado que, para o aumento da precisão das estimativas de crescimento e de produção em nível espacial, deve-se incluir covariáveis nas modelagens geoestatísticas, em pesquisas que identifiquem e recomendem as melhores variáveis. Dessa forma, este trabalho teve como objetivo mapear a distribuição espacial de variáveis dendrométricas obtidas a partir do inventário florestal em povoamento de teca, por meio da inclusão de covariáveis de sensoriamento remoto na modelagem geoestatística. Mediante um inventário florestal executado em 213 ha de plantio de teca, em 46 unidades amostrais de 900 m² foram obtidas as variáveis: volume do povoamento, área basal, média aritmética dos diâmetros a 1,3 m do solo, diâmetro médio quadrático, diâmetro dominante, média aritmética da altura total e altura dominante. Para avaliar a integração de variáveis do sensoriamento remoto ao inventário florestal, foram processadas imagens do satélite Landsat 8 sensor OLI para obtenção das seguintes covariáveis: razão simples, índice de vegetação da diferença normalizada, índice de vegetação melhorado, índice de vegetação ajustado ao solo, índice de vegetação resistente à atmosfera, índice de vegetação resistente à atmosfera na região do visível, primeira componente principal e transformação *tasseled cap*. Após a obtenção das variáveis do povoamento e de sensoriamento remoto, foram aplicados os métodos de krigagem simples e ordinária, cokrigagem ordinária e krigagem com deriva externa. A seleção dos melhores ajustes foi feita com base na menor soma dos quadrados dos desvios ponderados, no menor coeficiente de determinação e na validação cruzada. A krigagem simples, apesar de pouco explorada nas ciências florestais, gerou predições com baixos erros de estimação e semelhantes à krigagem ordinária, porém com maiores tendências nas estimativas, enquanto a cokrigagem ordinária mostrou-se inadequada para a predição dos padrões espaciais do povoamento de teca por meio de índices de sensoriamento remoto. Para o método de krigagem com deriva externa, apenas a variável diâmetro médio quadrático apresentou estatísticas de validação melhores que os outros métodos, porém, ao observar as medidas de viés, ela não superestimou consideravelmente os valores das variáveis do povoamento nas unidades amostrais, comparativamente aos outros métodos de krigagem. Assim, a krigagem com deriva externa permite predições dos padrões espaciais com maior nível de detalhamento, o que resulta em minimização de possíveis erros de suavização gerados pelos métodos tradicionais de krigagem simples e ordinária. Portanto, proporciona também recomendações mais precisas de intervenções localizadas ao manejo de plantios de teca, corroborando com as hipóteses formuladas nesta pesquisa.

Palavras-chave: Cokrigagem ordinária. Geoestatística multivariada. Krigagem com deriva externa. Krigagem universal. Teca.

ABSTRACT

Presenting as an alternative to forest plantations of high economic value species, teak offers a sustainable option for the Brazilian forest-based industry, also reducing the pressure of native forest exploitation. To develop management plans on a sustainable basis, detailed and adequate knowledge of their variables obtained from forest inventories is required. In this context, geostatistics has been tested and applied to guide the conduction of teak stands. However, it has been verified that to increase the accuracy of growth and production estimates at spatial level, covariates should be included in the geostatistical modeling, in which researches that identify and recommend the best variables is required. Thus, this study aimed to map the spatial distribution of forest variables obtained from forest inventory in teak stands, by including remote sensing covariables in geostatistical modeling. Through a forest inventory carried out on 213 ha of teak stand, in 46 sample units of 900 m² the following variables were obtained: stand volume, basal area, diameter at breast height, quadratic mean diameter, dominant diameter, total height and dominant height. In order to evaluate the integration of remote sensing variables and forest inventory, Landsat 8 OLI sensor satellite images were processed to obtain the following covariates: simple ratio, normalized difference vegetation index, improved vegetation index, soil adjusted vegetation index, atmospheric resistant vegetation, visible atmospheric resistant vegetation index, first principal component and tasseled cap transformation. After obtaining the stand and remote sensing variables, methods of simple kriging and, ordinary kriging, ordinary cokriging and kriging with external drift were applied. The selection of the best adjustments was made based on the smallest weighted sum of squares of deviations, lowest coefficient of determination and cross-validation. Simple kriging, although rarely explored in the forest sciences, produced predictions with low estimation errors and similar to ordinary kriging, but with greater estimates tendencies, while ordinary kriging was inadequate to predict teak stand spatial patterns by means of remote sensing indices. For the kriging with external drift, only the quadratic mean diameter variable showed better validation statistics than the other kriging methods, however, when the bias measures were observed, it did not significantly overestimate the stand variables values in the sample units when compared to other kriging methods. Thus, kriging with external drift allows spatial pattern predictions, resulting in minimization of possible smoothing errors produced by traditional simple and ordinary kriging methods. Therefore, it also provides more accurate recommendations for localized interventions for teak stand management, corroborating the hypotheses formulated in this research.

Keywords: Ordinary cokriging. Multivariate geostatistics. Kriging with external drift. Universal kriging. Teak.

LISTA DE FIGURAS

| | |
|--|----|
| FIGURA 1 – REPRESENTAÇÃO GRÁFICA DE UM SEMIVARIOGRAMA..... | 18 |
| FIGURA 2 – COORDENADAS GEOGRÁFICAS DO POVOAMENTO DE TECA E DISTRIBUIÇÃO ESPACIAL DAS UNIDADES AMOSTRAIS..... | 28 |
| FIGURA 3 – RELAÇÕES ENTRE AS VARIÁVEIS DO POVOAMENTO DE TECA... | 39 |
| FIGURA 4 – RELAÇÕES ENTRE AS VARIÁVEIS DE SENSORIAMENTO REMOTO EM POVOAMENTO DE TECA..... | 42 |
| FIGURA 5 – MAPAS TEMÁTICOS DAS VARIÁVEIS DE SENSORIAMENTO REMOTO EM POVOAMENTO DE TECA | 43 |
| FIGURA 6 – MATRIZ DE CORRELAÇÃO ENTRE AS VARIÁVEIS DO POVOAMENTO DE TECA E AS COVARIÁVEIS DE SENSORIAMENTO REMOTO | 46 |
| FIGURA 7 – RELAÇÕES ENTRE AS VARIÁVEIS DO POVOAMENTO DE TECA E DE SENSORIAMENTO REMOTO | 48 |
| FIGURA 8 – SEMIVARIOGRAMAS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO DE TECA | 51 |
| FIGURA 9 – DISTRIBUIÇÃO ESPACIAL DAS VARIÁVEIS DO POVOAMENTO POR KRIGAGEM SIMPLES DE TECA..... | 52 |
| FIGURA 10 – DISTRIBUIÇÃO ESPACIAL DAS VARIÁVEIS DO POVOAMENTO DE TECA POR KRIGAGEM ORDINÁRIA..... | 54 |
| FIGURA 11 – SEMIVARIOGRAMAS CRUZADOS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO DE TECA EM FUNÇÃO DAS COVARIÁVEIS DE SENSORIAMENTO REMOTO | 56 |
| FIGURA 12 – SEMIVARIOGRAMAS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO DE TECA EM FUNÇÃO DE COVARIÁVEIS DE SENSORIAMENTO REMOTO | 61 |
| FIGURA 13 – DISTRIBUIÇÃO ESPACIAL DAS VARIÁVEIS DO POVOAMENTO DE TECA POR KRIGAGEM COM DERIVA EXTERNA | 62 |

LISTA DE TABELAS

| | |
|---|----|
| TABELA 1 – CARACTERÍSTICAS DO SATÉLITE LANDSAT 8 SENSOR OLI..... | 29 |
| TABELA 2 – COEFICIENTES DA TRANSFORMAÇÃO <i>TASSELED CAP</i> PARA AS BANDAS DE REFLECTÂNCIA DO SENSOR OLI/LANDSAT-8..... | 31 |
| TABELA 3 – MODELOS TEÓRICOS DE SEMIVARIOGRAMAS | 32 |
| TABELA 4 – ANÁLISE ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS DO POVOAMENTO DE TECA | 37 |
| TABELA 5 – ANÁLISE ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS DE SENSORIAMENTO REMOTO EM POVOAMENTO DE TECA..... | 40 |
| TABELA 6 – ESTIMATIVAS DAS VARIÂNCIAS ASSOCIADAS AOS COMPONENTES PRINCIPAIS | 45 |
| TABELA 7 – PARÂMETROS DOS SEMIVARIOGRAMAS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO DE TECA..... | 49 |
| TABELA 8 – PARÂMETROS DOS SEMIVARIOGRAMAS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO DE TECA..... | 57 |
| TABELA 9 – ESTATÍSTICA DA VALIDAÇÃO CRUZADA DOS MÉTODOS DE KRIGAGEM PARA ESTIMATIVA DAS VARIÁVEIS DO POVOAMENTO DE TECA | 64 |

SUMÁRIO

| | |
|--|-----------|
| 1 INTRODUÇÃO | 14 |
| 1.1.1 Objetivo geral | 16 |
| 1.1.2 Objetivos específicos..... | 16 |
| 1.2 HIPÓTESES | 16 |
| 2 REVISÃO DE LITERATURA | 17 |
| 2.1 GEOESTATÍSTICA APLICADA AO MANEJO FLORESTAL | 17 |
| 2.1.1 Definição de geoestatística | 17 |
| 2.1.2 Geoestatística em povoamentos florestais | 19 |
| 2.1.3 Geoestatística em plantios de <i>Tectona grandis</i> | 20 |
| 2.2 SENSORIAMENTO REMOTO APLICADO AO MANEJO FLORESTAL..... | 20 |
| 2.2.1 Definição de sensoriamento remoto | 20 |
| 2.2.2 Variáveis de sensoriamento remoto em povoamentos florestais..... | 22 |
| 2.2.3 Sensoriamento remoto associado à geoestatística | 26 |
| 3 MATERIAL E MÉTODOS | 28 |
| 3.1 LOCAL DE ESTUDO..... | 28 |
| 3.2 VARIÁVEIS DENDROMÉTRICAS DO POVOAMENTO..... | 29 |
| 3.3 VARIÁVEIS DE SENSORIAMENTO REMOTO..... | 29 |
| 3.4 ANÁLISE EXPLORATÓRIA DOS DADOS | 31 |
| 3.5 ANÁLISE GEOESTATÍSTICA..... | 32 |
| 3.5.1 Modelagem de semivariogramas..... | 32 |
| 3.5.2 Interpolação espacial..... | 33 |
| 3.5.2.1 Krigagem simples | 33 |
| 3.5.2.2 Krigagem ordinária | 34 |
| 3.5.2.3 Cokrigagem ordinária..... | 34 |
| 3.5.2.4 Krigagem com deriva externa | 35 |
| 3.5.3 Avaliação dos métodos de krigagem | 36 |
| 4 RESULTADOS E DISCUSSÃO | 37 |
| 4.1 ANÁLISE EXPLORATÓRIA DAS VARIÁVEIS DO POVOAMENTO..... | 37 |
| 4.2 ANÁLISE EXPLORATÓRIA DAS VARIÁVEIS DE SENSORIAMENTO REMOTO..... | 40 |
| 4.3 RELAÇÕES ENTRE VARIÁVEIS DO POVOAMENTO E DE SENSORIAMENTO REMOTO..... | 46 |

| | |
|---|-----------|
| 4.4 KRIGAGEM SIMPLES..... | 49 |
| SUMÁRIO | |
| 4.5 KRIGAGEM ORDINÁRIA | 53 |
| 4.6 COKRIGAGEM ORDINÁRIA..... | 55 |
| 4.7 KRIGAGEM COM DERIVA EXTERNA..... | 57 |
| 4.8 AVALIAÇÃO DOS MÉTODOS DE KRIGAGEM | 63 |
| 5 CONCLUSÕES | 66 |
| REFERÊNCIAS..... | 67 |
| APÊNDICE 1 – APLICAÇÃO DOS MÉTODOS DE KRIGAGEM EM R..... | 76 |

1 INTRODUÇÃO

A *Tectona grandis* L. f., popularmente conhecida como teca, é uma espécie originária das florestas tropicais de monção do continente asiático, com distribuição natural na Índia, Mianmar, Tailândia e Laos (MIRANDA et al., 2011, DEB et al., 2017; TEWARI; SINGH, 2018). No Brasil, os plantios de teca tiveram início na década de 1970, com o objetivo de garantir a disponibilidade de madeira para a indústria regional (PASSOS et al., 2006). Em 2012, a produção de madeira em tora de teca representava 0,4% da produção total de madeira, cerca de 1,0 milhão m³ ano⁻¹, com produtividade média anual de 15 m³ ha⁻¹ (ABRAF, 2013). Atualmente, há aproximadamente 94 mil ha de plantios comerciais de teca no Brasil (IBÁ, 2019), localizados principalmente nas regiões Centro-Oeste e Norte.

A teca é uma espécie de rápido crescimento, cuja madeira é considerada nobre em função de sua durabilidade, resistente ao fogo, pragas e doenças e, por isso, muito utilizada na confecção de móveis de luxo e na construção naval (KOLLERT; KLEINE, 2017). Desse modo, a teca é uma alternativa aos plantios florestais de espécies de alto valor econômico para a produção sustentável da indústria de base florestal brasileira, ao mesmo tempo que reduz a pressão da exploração de florestas nativas (DRESCHER et al., 2014; SILVA et al., 2016).

Para o desenvolvimento de planos de manejo em bases sustentáveis, se faz necessário o adequado e detalhado conhecimento de suas variáveis dendrométricas obtidas a partir de inventários florestais. Porém, os procedimentos estatísticos tradicionais para processamento dos inventários florestais estimam a variável de interesse a partir de uma amostra. Contudo, é importante considerar as relações espaciais existentes entre as unidades amostrais para atender a silvicultura de precisão (CORONA, 2010; LEAL et al., 2014; ROVEDA et al., 2016). Assim, para a utilização da geoestatística, é necessária a prévia análise detalhada do comportamento espacial das características de um povoamento florestal.

Segundo a teoria das variáveis regionalizadas, desenvolvida por Matheron (1971), uma variável pode oscilar de um local para outro com uma continuidade, a qual se deve à tendência de os dados medidos geograficamente próximos resultarem em valores semelhantes. A geoestatística trata do estudo dessas variáveis regionalizadas e fornece um conjunto de técnicas para o entendimento espacial da

aleatoriedade dos dados, possibilitando a estimação de valores de uma dada variável para um local não amostrado (OLIVER; WEBSTER, 2014; KARAHAN; ERŞAHIN, 2018).

Em razão da peculiaridade do desenvolvimento da teca, que necessita um regime de manejo diferenciado das principais culturas florestais, como dos gêneros *Eucalyptus* e *Pinus*, a geoestatística tem sido testada e aplicada para direcionar a condução dos plantios dessa espécie (PELISSARI et al., 2014b; PELISSARI et al., 2017; GIL et al., 2018). Contudo, tem-se verificado que, para o aumento da precisão das estimativas de crescimento e produção em nível espacial, deve-se incluir covariáveis nas modelagens geoestatísticas (HERNÁNDEZ-STEFANONI et al., 2011; BENITEZ et al., 2016; REIS et al., 2016), necessitando-se, com isso, de estudos que identifiquem e recomendem as melhores covariáveis.

As covariáveis a serem empregadas em análises geoestatística devem apresentar algumas características, como baixo custo de aquisição e a alta densidade de pontos amostrados no espaço (HERNÁNDEZ-STEFANONI et al., 2011). Assim, o emprego de variáveis de sensoriamento remoto mostra-se uma hipótese viável para auxiliar a modelagem geoestatística, devido à facilidade de obtenção e por supostamente apresentarem valores de reflectância correlacionados com as variáveis dendrométricas, e podem fornecer informações referentes à estrutura e à produtividade ao longo de toda área de interesse, como subsídio para o manejo florestal.

Essa hipótese é fundamentada nas informações obtidas isoladamente por diferentes tecnologias de sensoriamento remoto, as quais têm demonstrado ampla aplicação para representação cartográfica da cobertura florestal, mapeamento da estrutura de florestas, melhoraria da precisão nas estimativas dendrométricas, apoio às operações de manejo florestal, entre outras (SOUZA et al., 2007; VIDAL et al., 2008; CORONA, 2010). Contudo, a integração de variáveis de sensoriamento remoto, como índices de vegetação, com a modelagem geoestatística em povoamentos florestais foi pouco explorada na literatura especializada, podendo-se destacar os estudos de Berterretche et al. (2005), Mutanga e Rugege (2006), Sales et al. (2007) e Hernández-Stefanoni et al. (2011). Ademais, para plantios florestais como teca, essa lacuna na área de conhecimento continua inexplorada.

OBJETIVOS

1.1.1 Objetivo geral

O objetivo geral deste trabalho foi mapear a distribuição espacial de variáveis dendrométricas obtidas a partir do inventário florestal em povoamentos de teca, por meio da inclusão de covariáveis de sensoriamento remoto na modelagem geoestatística.

1.1.2 Objetivos específicos

- a) Identificar a correlação entre variáveis dendrométricas de povoamentos de teca e de sensoriamento remoto;
- b) Empregar variáveis de sensoriamento remoto como covariáveis em modelagens geoestatística de povoamentos de teca;
- c) Avaliar o desempenho das krigagens simples e ordinária, cokrigagem ordinária e krigagem com deriva externa para a estimativa de variáveis dendrométricas de povoamentos de teca.

1.2 HIPÓTESES

- a) As variáveis de sensoriamento remoto, associadas como covariáveis nas modelagens geoestatística, possibilitam o aumento da precisão estatística da predição espacial de variáveis dendrométricas de povoamentos de teca.
- b) A partir do mapeamento da distribuição espacial de variáveis dendrométricas de povoamentos de teca, é possível obter informações com precisão estatística da produção e da produtividade como subsídios ao manejo florestal.

2 REVISÃO DE LITERATURA

2.1 GEOESTATÍSTICA APLICADA AO MANEJO FLORESTAL

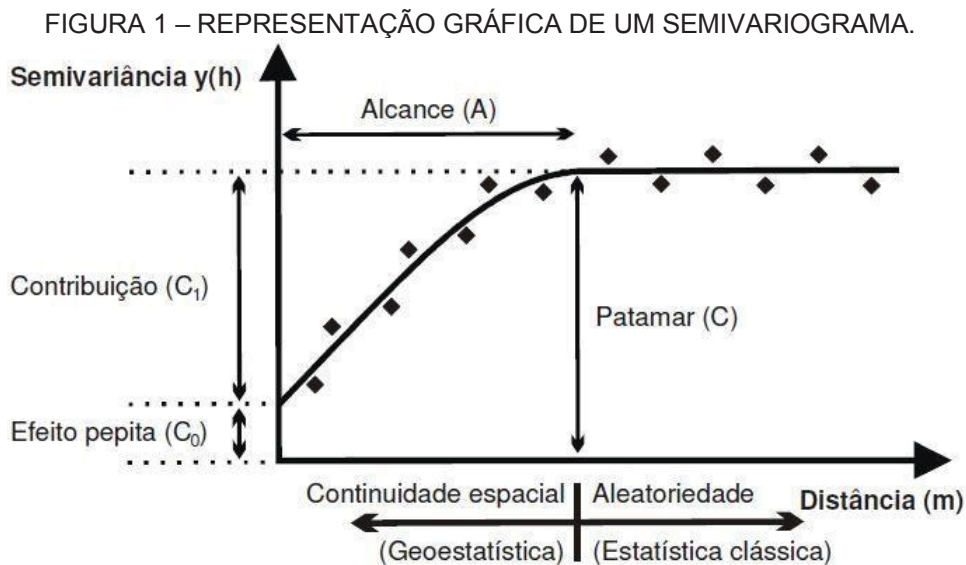
2.1.1 Definição de geoestatística

A geoestatística trata do estudo das variáveis aleatórias dependentes do espaço, conhecidas como variáveis regionalizadas. As variáveis regionalizadas podem ser definidas como qualquer variável dependente do espaço que tenha caráter aleatório e estrutural, mostrando continuidade aparente, e cujas variações são previstas por uma função estocástica (YAMAMOTO; LANDIM, 2013). Por meio da geoestatística, é possível descrever e modelar padrões espaciais para prever valores em locais não amostrados, além de obter a incerteza associada a esse valor estimado (ANDRIOTTI, 2003).

A determinação do modelo de correlação espacial da variável regionalizada consiste em duas etapas: 1º) construção do semivariograma experimental para interpretação da continuidade espacial dos pontos amostrais; e 2º) modelagem da estrutura espacial com ajuste de um semivariograma teórico (KANEVSKI; MAIGNAN, 2004; YAMAMOTO; LANDIM, 2013).

O semivariograma é uma função que mede a variância entre pontos separados por uma distância h . Assim, quanto maior a distância maior será a variabilidade entre os pontos amostrais, com aumento da variância até sua estabilização em torno de uma variância máxima denominada patamar (YAMAMOTO; LANDIM, 2013). A estrutura de um semivariograma com patamar (FIGURA 1) é composta de (YAMAMOTO; LANDIM, 2013):

- Alcance ou amplitude ou *range* (a): distância segundo a qual as amostras passam a ser independentes e sem correlação espacial;
- Patamar ou *sill* (C_0+C): ponto em que o valor da variância se estabiliza;
- Efeito pepita ou *nugget effect* (C_0): refere-se ao valor da semivariância para a distância zero, além de indicar a variação ao acaso ou erros de amostragem em razão de sua escala; e
- Contribuição ou variância espacial ou variância *a priori* (C): diferença entre o patamar e o efeito pepita.



FONTE: PELISSARI (2012a).

Com base no conhecimento dos parâmetros básicos que caracterizam um semivariograma, é possível ajustar modelos teóricos que possam explicar a variabilidade da grande maioria dos fenômenos espaciais. Caso não exista homogeneidade das distribuições das variâncias em ângulos diferentes, considera-se que os fenômenos espaciais apresentam anisotropia. Sendo assim, para identificar a presença de anisotropia, recomenda-se o cálculo do semivariograma em quatro direções distintas, geralmente 0° , 45° , 90° e 135° no plano espacial (ANDRIOTTI, 2003; YAMAMOTO e LANDIM, 2013).

Constatada a dependência espacial entre as unidades amostrais e executada a modelagem do semivariograma teórico, procede-se a etapa de interpolação e espacialização das variáveis pelo método de krigagem. A krigagem é um método de interpolação que visa determinar os pesos das amostras envolvidas na estimativa de valores em locais não amostrados, além de apresentar estimativas não tendenciosas com mínima variância (ANDRIOTTI, 2003; YAMAMOTO; LANDIM, 2013).

Em seguida, realiza-se a validação cruzada, onde cada valor original é removido do domínio espacial e, usando-se os demais, um novo valor é estimado para esse ponto. Assim, um gráfico pode ser construído mostrando a relação entre os valores observados e estimados. Se os resultados da validação cruzada apresentarem dispersão pequena em torno da reta de regressão, é confirmada a existência de uma estimativa adequada, caso contrário pode indicar a presença de viés. Porém, a validação cruzada, não prova que o modelo escolhido esteja correto,

apenas que esse não é, necessariamente, incorreto. Logo, a melhor verificação é aquela resultante do confronto entre valores estimados (LANDIM, 2006).

2.1.2 Geoestatística em povoamentos florestais

Nas atividades florestais, a base para o planejamento e uso de seus recursos é o conhecimento de suas características qualitativas e quantitativas. Essas informações são obtidas por meio de inventários florestais, no qual são exigidas atualizações constantes de registros e mapas com informações espacializadas de interesse (PÉLLICO NETTO; BRENA, 1997; SOUZA et al., 2007). Porém, o processamento dessas informações é realizado por métodos estatísticos tradicionais que não exploram a distribuição espacial e as relações que possam existir entre as unidades amostrais. Desse modo, a geoestatística é uma alternativa para aumentar a precisão e aprimorar o processamento dos inventários florestais, uma vez que possibilita explorar as relações espaciais entre as características dendrométricas de uma espécie e as variáveis do seu meio abiótico (BOGNOLA et al., 2008).

Desde o seu início na mineração, a geoestatística se difundiu em várias áreas de aplicação, como hidrologia, meteorologia e agricultura. Entretanto, na área florestal, as pesquisas só ganharam ênfase com a obra *Spatial Variation* (MATÉRN, 1960) desenvolvida pelo estatístico florestal Bertil Matérn (WEBSTER; OLIVER, 2007; PELISSARI, 2015). Sendo assim, a geoestatística apresenta potencial para caracterizar o comportamento espacial de variáveis dendrométricas de povoamento e formações florestais. Como é o caso da pesquisa desenvolvida por Samra et al. (1989), que realizaram uma modelagem geoestatística do crescimento em altura para *Melia azedarach* na Índia.

Outras aplicações da geoestatística na área florestal são: determinação do grau de dependência espacial para definição de estratos (GUEDES et al., 2012); determinação do estoque de madeira em povoamento de eucalipto e avaliação da potencialidade de mapas de produtividade florestal utilizando a geoestatística (SANTOS et al., 2017); espacialização do estoque volumétrico para os sortimentos de madeira de povoamentos de *Pinus* sp. (CALIXTO et al., 2017); e avaliação da dinâmica e modelagem da continuidade espacial do estoque e área basal total em diferentes classes diamétricas de um remanescente de Floresta Ombrófila Mista

(ROVEDA, 2018);

2.1.3 Geoestatística em plantios de *Tectona grandis*

A expansão da indústria de base florestal brasileira gera aumento na demanda por matéria-prima de qualidade, principalmente no setor de florestas plantadas. Dessa forma, os povoamentos de teca surgem como alternativa às espécies de elevado valor econômico, como o Mogno (*Swetenia macrophylla* G. King) e a Cerejeira (*Torresia acreana* Ducke), fornecendo madeira de qualidade às indústrias (DRESCHER et al., 2014; PELISSARI et al., 2014a).

Embora os plantios de teca tenham ganhado destaque no setor florestal brasileiro, os conhecimentos do manejo da espécie são insuficientes e muitas vezes inadequados. Isso se deve ao crescimento elevado da espécie nas América Central e do Sul, bem como as características edafoclimáticas particulares, que dificultam a realização de comparações com regimes de manejo de outras regiões (PELISSARI et al., 2014a).

Assim, para a obtenção de informações mais detalhadas sobre o manejo de teca, consolida-se a utilização da geoestatística para alcance de informações precisas e de baixo custo que direcionem a condução dos plantios da espécie. Vários estudos demonstraram que a estrutura espacial é uma característica presente nas variáveis dendrométricas de povoamentos de teca, tais como: modelagem geoestatística da altura dominante de teca (PELISSARI et al., 2012b); modelagem geoestatística do volume e da área basal de povoamentos de teca, pré-desbastes seletivos (PELISSARI et al., 2014b); estimar a variabilidade espacial do volume de sortimentos de madeira e identificar seus padrões espaciais em povoamentos de teca (PELISSARI et al., 2017); modelagem espacial da variabilidade dos atributos químicos do solo em plantios de teca (GIL et al., 2018).

2.2 SENSORIAMENTO REMOTO APLICADO AO MANEJO FLORESTAL

2.2.1 Definição de sensoriamento remoto

O sensoriamento remoto é a tecnologia que permite o estudo de eventos,

fenômenos e processos que ocorrem na superfície do planeta Terra a partir de um conjunto de sensores instalados em plataformas aéreas e/ou orbitais (NOVO, 2010; FLORENZANO, 2011). Esses sensores podem ser entendidos como equipamentos capazes de captar a energia refletida ou emitida pela superfície terrestre e registrá-la na forma de dados digitais, como imagens, gráficos e dados numéricos. Esses são passíveis de serem armazenados, manipulados e analisados por meio de *softwares* específicos (FITZ, 2008).

Os dados de sensoriamento remoto são coletados por sistemas sensores passivos ou ativos. Os sensores ativos emitem as ondas eletromagnéticas e, em seguida, registram a radiação espalhada de volta pela superfície terrestre em direção ao sensor, por exemplo, os radares LIDAR e SONAR. Por outro lado, os sensores passivos captam a radiação eletromagnética refletida ou emitida pela superfície terrestres.

O processo de aquisição de informações por sensores remotos passivos, segundo Centeno (2004), se resume aos seguintes passos: a energia eletromagnética, proveniente do sol, se propaga através da atmosfera até atingir a superfície terrestre, interagindo com ela; em seguida, parte dessa energia, que pode ser absorvida, refletida ou transmitida, é captada/registrada pelo sistema sensor colocado a bordo de aeronaves, espaçonaves ou outras plataformas, gerando assim uma informação digital que é transmitida a uma estação de recepção na Terra.

Após a aquisição das informações, a transformação dos dados é realizada para um formato de fácil interpretação, como imagens digitais. Para tanto, é necessário abordar as principais características das imagens, que é dada em função das resoluções espacial, espectral, radiométrica e temporal (CENTENO, 2004).

A resolução espacial é a menor feição passível de detecção pelo sensor sobre a superfície da terra ou objeto dentro de um ângulo de visada (NOVO, 2010). Ela está associada ao número de bandas espectrais de um sistema sensor e a amplitude do intervalo de comprimento de onda de cada banda (SILVA, 2009). Segundo Centeno (2004), quanto maior o número de bandas e menor a amplitude do comprimento de onda, maior é a capacidade do sistema em registrar diferenças espectrais entre os objetos, aumentando assim a sua resolução espectral.

A resolução radiométrica está associada à sensibilidade do sensor, representando os níveis de cinza, que é dado pelo número de valores digitais. A

radiação radiométrica é medida na quantidade de *bits* (dígitos binários) necessários para armazenar, em forma digital, os dados correspondentes a um *pixel* (CENTENO, 2004; SILVA, 2009). A resolução temporal refere-se ao mínimo intervalo de tempo que o sensor necessita para imagear uma determinada área. Quanto maior o intervalo de tempo, menor é a resolução temporal (CENTENO, 2004).

2.2.2 Variáveis de sensoriamento remoto em povoamentos florestais

O sensoriamento remoto passou por grandes avanços desde o início do século XX, principalmente em virtude do desenvolvimento de sensores mais potentes que proporcionaram ao longo do tempo imagens com resoluções melhores, associadas às técnicas de extração de informações oriundas do processamento de imagens. Assim, a aplicação do sensoriamento remoto foi ampliada para diversas áreas do conhecimento, como: levantamento de recursos ambientais, geologia, agricultura, estudos urbanos, análise ambiental, entre outros (ROCHA, 2000).

Segundo Boyd e Danson (2005), o uso do sensoriamento remoto em estudos florestais fornece três níveis de informações: o primeiro refere-se a extensão da cobertura vegetal, usada para analisar a dinâmica da cobertura florestal; o segundo compreende informações sobre o tipo de floresta; e o terceiro sobre as propriedades biofísicas e bioquímicas da floresta (como índice de área foliar, volume de madeira, idade do plantio, altura média e área basal), que fornecem informações para o manejo e a qualidade do recurso florestal.

As folhas das árvores desempenham um papel importante nos vegetais, tendo como função principal viabilizar a interação com a radiação eletromagnética na faixa visível (0,4 μm a 0,72 μm). A interação dessa radiação com a estrutura celular de uma folha é em função de sua composição, morfologia e estrutura interna. Assim, características geneticamente controladas, apresentarão diferenças no comportamento espectral entre grupos geneticamente distintos. Dessa forma, a quantidade de energia absorvida, transmitida ou refletida pelas folhas, pode diferir de uma espécie para outra, ou até mesmo dentro da própria espécie, porque existem, dentre outros fatores, influência direta ou indireta das condições ambientais nessa interação (PONZONI, 2001; PONZONI et al., 2012; MOREIRA, 2011).

Com relação a resposta espectral de uma folha típica, considera-se três faixas

do espectro eletromagnético: na região do visível (0,4 – 0,7 μ m) observa-se baixa reflectância devido à absorção da radiação incidente pelos pigmentos, como as clorofilas e os carotenoides; na região do infravermelho próximo (0,7 – 1,3 μ m) a reflectância das folhas é alta devido as múltiplas reflexões da radiação nas paredes das células; e na região do infravermelho médio (1,3 – 2,6 μ m), o teor de água contido nas folhas é responsável pela absorção em 1,40 e 1,95 μ m diminuindo a reflectância da folha. Além disso, o comportamento espectral das folhas também pode ser caracterizado pela banda *red edge* no intervalo de comprimento de onda entre 0,68 – 0,75 μ m (GATES et al., 1965; KNIPLING, 1970; e GUYOT et al., 1990).

A radiação eletromagnética na superfície vegetal apresenta diferentes respostas morfológicas e fisiológicas no componente vegetal, ou no ecossistema como um todo. Quando comparada com uma folha, a resposta espectral de uma floresta, apresenta maior influência do solo, das condições climáticas e das alterações da vegetação, sendo a reflectância espectral de folhas isoladas diferente daquela apresentada pelos dosséis (LILLESAND; KIEFER, 1994; SILVA; PONZONI, 1995).

Segundo GUYOT (1990), interpretar dados detectados por sensores remotos em dosséis de floresta exige conhecimento dos seguintes fatores externos que afetam suas propriedades ópticas: tamanho da área imageada, orientação e inclinação da linha central da vista, elevação do sol, nebulosidade e velocidade do vento, e ainda, fatores internos, que podem afetar a reflectância da floresta: propriedades ópticas da superfície do solo e arquitetura do dossel. Além disso, a organização e arranjo espacial das folhas no dossel afeta diretamente a quantidade de luz absorvida pelo sistema.

Com o objetivo de explorar as propriedades espectrais da vegetação, diversos índices de vegetação foram desenvolvidos, especialmente na região da luz visível e infravermelho próximo. Os índices de vegetação são medidas radiométricas adimensionais, com registro da abundância relativa de vegetação verde e são relacionados aos parâmetros biofísicos da cobertura vegetal, como biomassa, índice de área foliar, porcentagem de cobertura verde e teor de clorofila. Além disso, há redução dos efeitos de iluminação da cena, declividade da superfície e geometria de aquisição, que influenciam os valores de reflectância da vegetação (JENSEN, 2009; PONZONI et al., 2012).

Desde a década de 1960, vários índices de vegetação foram desenvolvidos,

de modo que, a seguir são apresentados os principais disponíveis na literatura: a) Índice de vegetação da razão simples (SR) (BIRTH; MCVEY, 1968); b) Índice de vegetação por diferença normalizada (NDVI) (ROUSE et al., 1974); c) Índice de vegetação perpendicular (PVI) (RICHARDSON; WIEGAND, 1977); d) Índice de vegetação ajustado ao solo (SAVI) (HUETE, 1988); e) Índice de vegetação realçado (EVI) (HUETE et al., 1997); f) Índice de vegetação resistente à atmosfera (ARVI) (KAUFMAN; TANRÉ, 1992); g) Índice resistente à atmosfera no visível (VARI) (GITELSON et al., 2002); e Índice de Área Foliar (IAF) (DUCHEMIN et al., 2006).

A razão simples (SR) foi o primeiro índice a ser usado e fornece informações sobre a biomassa da vegetação ou sobre o Índice de Área Foliar (IAF), sendo sensível às variações da mesma (JORDAN, 1969; JENSEN, 2009) e apropriado para análises absolutas em uma imagem. Assim, para a comparação relativa entre cenas multiespectrais, Rouse et al. (1974) normalizaram a SR para o intervalo de -1 a +1, resultando no Índice de Vegetação da Diferença Normalizada (NDVI).

O NDVI é uma ferramenta para o monitoramento da vegetação e utilizado para construção de perfis sazonais e temporais das atividades da vegetação, o que permite comparações interanuais desses perfis (PONZONI et al., 2012; ZANOTTA et al., 2019). Os valores mais elevados de NDVI estão relacionados às áreas com maior quantidade de vegetação fotossinteticamente ativa, enquanto os valores baixos representam as áreas com menor vegetação.

O Índice de Vegetação Melhorado (EVI), que recebe essa sigla pelo seu nome em inglês *Enhanced Vegetation Index*, foi desenvolvido originalmente para o sensor Modis e inclui a banda do azul. O EVI é um NDVI modificado e provou ser mais sensível às mudanças estruturais do dossel e menos suscetível à saturação em condições de elevada biomassa (JENSEN, 2009; ZANOTTA et al., 2019).

O Índice de Vegetação Ajustado ao Solo - SAVI (*Soil-Adjusted Vegetation Index*) é um outro índice importante derivado do NDVI para minimizar as influências do brilho do solo, por meio da introdução de uma constante L , e assim é destacada a resposta da vegetação (JENSEN, 2009; ZANOTTA et al., 2019). Segundo Huete e Liu (1994), um valor de L igual a 0,5 minimiza as variações de brilho dos solos, eliminando a necessidade de calibrações adicionais para diferentes solos.

Com o objetivo de reduzir a influência da atmosfera, o Índice de Vegetação Resistente a Atmosfera - ARVI (*Atmospherically Resistant Vegetation Index*) foi

desenvolvido por meio da inclusão da banda do azul e de uma constante γ que compensa a presença de aerossóis atmosférico (ZANOTTA et al., 2019). Segundo Kaufman e Tanré (1992), o valor ótimo de γ para aplicações de sensoriamento remoto é igual a 1. Assim, o *ARVI* é quatro vezes menos sensível ao efeito da turbidez atmosférica do que o *NDVI*, sendo mais favorável para superfícies cobertas pela vegetação.

Com base no *ARVI*, o Índice de Vegetação Resistente à Atmosfera na Região do Visível - *VARI* (*Visible Atmosferically Resistant Index*) foi desenvolvido. Este índice é muito pouco sensível aos efeitos atmosféricos, permitindo a estimação da vegetação com erro menor que 10% em uma grande variedade de espessuras ópticas atmosféricas (JENSEN, 2009).

Segundo Moita Neto e Moita (1998), a análise de componentes principais (*CP*) consiste em reescrever as coordenadas das amostras em outro sistema de eixo mais conveniente para a análise de dados. Com isso, as n -variáveis originais geram, por meio de suas combinações lineares, n -componentes principais em ordem crescente de máxima variância. Assim, a componente principal 1 detém mais informações estatística que a componente principal 2, e assim por diante. Segundo Zanotta et al. (2019), um dos objetivos da *CP* é produzir novas componentes que, quando confrontadas, não apresentem correlação entre as *CP*, para que sua informação seja inédita e contribua para a análise.

Enquanto os índices de vegetação são baseados em diferentes combinações algébricas de bandas, a transformação *Tasseled Cap* – *TC* (ou transformações de Kauth-Thomas) produz uma transformação ortogonal das bandas do sensor MSS/Landsat que reprojeta os dados em três eixos: 1) o índice brilho do solo (*Brightness*, representado por *B*), capaz de indicar o tipo de solo; 2) o índice verdor da vegetação (*Greenness*, representado por *G*), que corresponde ao teor vegetativo do pixel e que registra valores maiores à medida que a quantidade de biomassa aumenta; e 3) o índice de material amarelo (*Yellow stuff*, denominado por *Y*). Dependendo do sensor utilizado, é possível existirem outros eixos ortogonais adicionais, como por exemplo os sensores TM, ETM+ e OLI dos posteriores satélites Landsat, em que o terceiro eixo corresponde a umidade do solo ou plantio (*Wetness*, denominado de *W*) (JENSEN, 2009; ZANOTTA et al., 2019).

O índice de área foliar (*IAF*) é um índice biofísico definido pela razão entre a

área foliar de uma vegetação por unidade de área utilizada por essa vegetação, sendo um indicador de biomassa de cada *pixel* da imagem.

2.2.3 Sensoriamento remoto associado à geoestatística

Nos estudos florestais, o inventário é uma técnica imprescindível para a obtenção de informações precisas e fidedignas das variáveis dendrométricas do povoamento. Porém, a medição de todos os indivíduos é inviável, devido ao tempo necessário e ao alto custo e, dessa forma, realizam-se estimativas dos parâmetros através de amostras da população. Esse método tradicional de inventário pode ser integrado com dados de sensoriamento remoto, que fornecem informações para o mapeamento da distribuição e localização de florestas e, quando possível, obtenção de dados sobre densidade, volume das árvores, estado fitossanitário, entre outros (SANQUETTA et al., 2014; MENESES et al., 2019).

O desenvolvimento das tecnologias dos sensores permitiu a aquisição de dados de sensoriamento remoto em diversas escalas, desde imagens de média resolução espacial com 20 – 30 m, como por exemplo as de Landsat TM, Landsat ETM+ e SPOT HRVIR, até imagens com 5 m consideradas de alta resolução, as de IKONOS, QuickBird e LIDAR (AHMED et al., 2015).

Segundo Meng et al. (2009), a integração de tecnologias geoespaciais permite a obtenção de métricas florestais, por meio da modelagem das relações entre os números digitais da imagem e as variáveis florestais inventariadas em campo com aparelhos GPS (Sistema de Posicionamento Global, em inglês, *Global Positioning System*). Os sistemas de informação geográfica e a modelagem espacial são ferramentas eficientes para modelar, estimar, mapear e prever características espaciais de povoamentos ou árvores.

Nesse sentido, técnicas de modelagem geoestatística, aliadas a dados de campo e de sensores remotos, apresentam-se como alternativa viável para predição espacial de variáveis dendrométricas de povoamentos. Procedimentos de geoestatística que combinam a krigagem com variáveis auxiliares são sugeridos para aumento da precisão das estimativas. Essa variável auxiliar geralmente é mais intensamente amostrada do que a variável principal, por ser de fácil obtenção e mais barata, reduzindo o custo de amostragem (HERNÁNDEZ-STEFANONI et al., 2011).

Os métodos geoestatísticos que usam uma variável auxiliar são: cokrigagem, cokrigagem colocalizada, krigagem com deriva externa e krigagem com regressão. Esses métodos diferem na maneira como utilizam as informações auxiliares para estimar a variável de interesse em locais não amostrados. Na cokrigagem, por exemplo, as duas variáveis são espacialmente correlacionadas e possuem um semivariograma cruzado usado para quantificar a covariância entre elas, que por sua vez é utilizado no procedimento de interpolação (HERNÁNDEZ-STEFAÑONI et al., 2011).

Em diversos estudos foram combinadas variáveis auxiliares com métodos de krigagem para examinar a possibilidade de aumento da precisão nas estimações de variáveis de interesse. A cokrigagem foi utilizada com sucesso por Mutanga e Rugege (2006) para mapear a biomassa herbácea na savana tropical; Georgakarakos e Kitsiou (2008) mapearam a distribuição da abundância de pequenas espécies pelágicas usando dados de sensoriamento remoto como variável auxiliar; e Sales et al. (2007) utilizaram a elevação, tipo de vegetação e textura do solo para melhorar a predição espacial de biomassa florestal, utilizando a krigagem com deriva externa.


Outros estudos foram conduzidos para estimativas de variáveis relevantes à silvicultura usando modelos espaciais como: Tuominen et al. (2003), Zhang et al. (2004), Maselli e Chiesi (2006), Buddenbaum et al. (2005) e Berterretche et al. (2005), que aplicaram modelos geoestatísticos para estimar variáveis dendrométricas, como índice de área florestal e para classificar terras florestais com base em dados de sensoriamento remoto. Destaca-se também os estudos de Yadav e Nandy (2015), os quais mapearam a biomassa florestal a partir da integração de dados de inventário florestal, sensoriamento remoto e técnicas geoestatísticas; e Oliveira et al. (2018), que utilizaram dados de sensoriamento remoto e modelagem geoestatística para analisar a precisão de estimativas volumétricas em plantios de eucalipto.

3 MATERIAL E MÉTODOS

3.1 LOCAL DE ESTUDO

Os dados utilizados neste estudo foram obtidos em um empreendimento da Teca do Brasil Florestal Ltda. no município de Nossa Senhora do Livramento, estado de Mato Grosso, Brasil, em um povoamento seminal de teca (*Tectona grandis* L. f.) com 19 anos de idade e implantado no espaçamento inicial de 3 m x 3 m em 213 ha (FIGURA 2). O clima da região é do tipo tropical Aw (Köppen), com estação seca no inverno, precipitação média de 1.300 mm ano⁻¹ e temperatura média anual de 25° C (ALVARES et al., 2014). O relevo é caracterizado como suavemente ondulado e o solo é classificado como PLANOSSOLO Háplico Eutrófico (SANTOS et al., 2018) de textura franco-argilo-arenosa.

FIGURA 2 – COORDENADAS GEOGRÁFICAS DO POVOAMENTO DE TECA E DISTRIBUIÇÃO ESPACIAL DAS UNIDADES AMOSTRAIS.



Coordenadas X
FONTE: O autor (2020).

Os tratos silviculturais realizados no povoamento foram: desbaste do tipo seletivo aos seis, nove, doze, quatorze, dezessete, dezenove anos de idade, com remoção média de 35% do plantio inicial, e 17%, 11%, 5%, 9%, 3% do total de árvores

remanescentes, respectivamente nos demais anos. As desramas foram executadas no segundo, terceiro e quarto ano, sendo seguidas por desramas de manutenção nas idades seguintes.

3.2 VARIÁVEIS DENDROMÉTRICAS DO POVOAMENTO

Para a coleta das variáveis do povoamento, foram alocadas 46 parcelas (FIGURA 2) georreferenciadas de 900 m² (30 m x 30 m), correspondendo a uma densidade inicial de 100 árvores por unidade amostral. Nessas parcelas, os valores das seguintes variáveis dendrométricas foram obtidos, após a realização do desbaste: V – volume do povoamento (m³ ha⁻¹), G – área basal (m² ha⁻¹), \bar{d} – média aritmética dos diâmetros a 1,3 m do solo (cm), d_g – diâmetro médio quadrático (cm), d_{dom} – diâmetro dominante (cm); \bar{h} – média aritmética das alturas (m); e h_{dom} – altura dominante (m). As árvores dominantes foram definidas de acordo com o critério de Assmann (1970).

3.3 VARIÁVEIS DE SENSORIAMENTO REMOTO

Para a obtenção das variáveis de sensoriamento remoto, imagens do Landsat 8 sensor OLI (TABELA 1) foram adquiridas no portal *Earth Explorer* do Serviço Geológico dos Estados Unidos (USGS, 2019). As imagens selecionadas encontravam-se ortorretificadas, com mínima interferência de nuvens e reprojetaadas para UTM-SIRGAS 2000 - Fuso 21S.

TABELA 1 - CARACTERÍSTICAS DO SATÉLITE LANDSAT 8 SENSOR OLI.

| Resolução espacial | Câmara | Resolução espectral (µm) | Resolução temporal | Largura da faixa de imageamento | Data de aquisição |
|--------------------|--------|--------------------------|--------------------|---------------------------------|-------------------|
| Multiespectral: | OLI | 1) 0,43 - 0,45 | 16 dias | 185 km | 08/03/2018 |
| 30 m | | 2) 0,45 - 0,51 | | | |
| Pancromática: | | 3) 0,53 - 0,59 | | | |
| 15 m | | 4) 0,64 - 0,67 | | | |
| | | 5) 0,85 - 0,88 | | | |
| | | 6) 1,57 - 1,65 | | | |
| | | 7) 2,11 - 2,29 | | | |
| | | 8) 0,50 - 0,68 | | | |

FONTE: USGS (2019).

Em seguida, o processamento digital das imagens de satélite foi realizado, o qual envolveu a manipulação das imagens, visando a melhoria da qualidade dos dados a sua futura interpretação (NOVO, 2010). Comumente, imagens adquiridas por satélite contém erros nos valores digitais registrados para os *pixels*, denominados de distorções radiométricas, que podem ser provocadas pelos próprios instrumentos utilizados no imageamento ou pela interferência da atmosfera na propagação da radiação (ZANOTTA et al., 2019). Desse modo, os números digitais (ND) das imagens foram convertidos para valores de parâmetros físicos, como radiância e reflectância, o que nos possibilitou efetuar cálculos com diferentes bandas espectrais (PONZONI et al., 2012).

A calibração foi realizada no *software* QGIS (QGIS DEVELOPMENT TEAM, 2019) de forma automática, o que envolveu a utilização de equações com coeficientes de regressão fornecidos pelos arquivos de metadados que acompanham a imagem. Na sequência, a fusão das bandas multiespectrais com a pancromático foi realizada no *software* ENVI Classic 5.0 (ENVI, 2015), com o objetivo de obter imagens com a melhor resolução espacial. As imagens foram recortadas, visando reduzir o tempo de processamento ao limitar a área de abrangência.

Posteriormente, índices de vegetação foram gerados a partir de operações aritméticas realizadas entre as bandas da imagem, sendo eles: *SR* – Razão Simples (1); *NDVI* – Índice de Vegetação da Diferença Normalizada (2); *EVI* – Índice de Vegetação Melhorado (3); *SAVI* – Índice de Vegetação Ajustado ao Solo (4); *ARVI* – Índice de Vegetação Resistente à Atmosfera (5); *VARI* – Índice de Vegetação Resistente à Atmosfera na Região do Visível (6) e; *IAF* – Índice de Área Foliar.

$$SR = \frac{NIR}{RED} \quad (1)$$

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (2)$$

$$EVI = FG \frac{NIR - RED}{(NIR + C_1)(RED - C_2)(BLUE + L)} (1 + L) \quad (3)$$

$$SAVI = \frac{(NIR - RED)(1 + L)}{(NIR + RED + L)} \quad (4)$$

$$ARVI = \frac{NIR - RB}{NIR + RB} \quad (5)$$

$$VARI = \frac{GREEN - RED}{GREEN + RED - BLUE} \quad (6)$$

$$IAF = \frac{\ln(1 - NDVI)}{-0,54} \quad (7)$$

Em que: *NIR* = reflectância na banda infravermelho próximo; *RED* = reflectância na banda vermelho; *BLUE* = reflectância na banda azul; *GREEN* = reflectância na banda verde; *FG* = fator de ganho igual a 2,5; *L* = fator de ajuste para solos igual 1; *C*₁ e *C*₂ = coeficientes da banda azul para correção da banda vermelha em função do espalhamento atmosférico por aerossóis, em *C*₁ = 6 e *C*₂ = 7,5; e *RB* = *RED* - γ (*BLUE* - *RED*).

A análise de Componentes Principais foi realizada no *software* ArcGIS (ESRI, 2016) em *Classification*, opção *Principal Component*. Na TABELA 2 estão os coeficientes utilizados para derivar as componentes *Tasseled Cap* para o sensor OLI/Landsat 8.

TABELA 2 – COEFICIENTES DA TRANSFORMAÇÃO *TASSELED CAP* PARA AS BANDAS DE REFLECTÂNCIA DO SENSOR OLI/LANDSAT-8

| | Banda 2 | Banda 3 | Banda 4 | Banda 5 | Banda 6 | Banda 7 |
|------------------------|---------|---------|----------|---------|---------|---------|
| | Azul | Verde | Vermelho | | | |
| <i>Brightness</i> | 0,3029 | 0,2786 | 0,4733 | 0,5599 | 0,508 | 0,1872 |
| <i>Greenness</i> | -0,2941 | -0,243 | -0,5424 | 0,7276 | 0,0713 | -0,1608 |
| <i>Wetness</i> | 0,1511 | 0,1973 | 0,3283 | 0,3407 | -0,7117 | -0,4559 |
| <i>TC</i> ₄ | -0,8239 | 0,0849 | 0,4396 | -0,058 | 0,2013 | -0,2773 |
| <i>TC</i> ₅ | -0,3294 | 0,0557 | 0,1056 | 0,1855 | -0,4349 | 0,8085 |
| <i>TC</i> ₆ | 0,1079 | -0,9023 | 0,4119 | 0,0575 | -0,0259 | 0,0252 |

FONTE: Baig et al. (2014) e Zanotta et al. (2019).

3.4 ANÁLISE EXPLORATÓRIA DOS DADOS

Com as variáveis do povoamento e de sensoriamento remoto, estatísticas descritivas foram aplicadas para verificar o comportamento dos dados, além da

presença de valores atípicos. Essa etapa foi constituída pela determinação das medidas de posição e de variabilidade dos dados; a avaliação da normalidade pelo teste de Anderson-Darling, ao nível de 5% de significância; as análises de correlação linear e sua classificação (SCHÖBER et al., 2018), diagramas de dispersão e regressão linear, com o objetivo de observar associações lineares e não-lineares entre as variáveis do povoamento e de sensoriamento remoto; e histogramas de frequências, visando identificar e corrigir distribuições assimétricas positivas, as quais são prejudiciais à modelagem geoestatística (YAMAMOTO; LANDIM, 2013).

3.5 ANÁLISE GEOESTATÍSTICA

3.5.1 Modelagem de semivariogramas

Após a análise exploratória, as semivariâncias experimentais (8) foram calculadas para identificar a dependência espacial entre as unidades amostrais. Para descrever a estrutura da dependência espacial, foram utilizados os seguintes modelos de semivariogramas teóricos (Tabela 3): Esférico (9), Exponencial (10), Gaussiano (11), Pentaesférico (12) e Circular (13). Esses modelos foram ajustados com o auxílio do programa R (R CORE TEAM, 2019) e o pacote *gstat* (PEBESMA, 2004). Um estudo dirigido, exemplificando a aplicação da metodologia no ambiente R, pode ser consultado no item Apêndice.

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(X_i) - Z(X_i + h)]^2 \quad (8)$$

Em que: $\gamma(h)$ = semivariância da variável Z ; h = distância; e $N(h)$ = número de pares de pontos medidos $Z(X_i)$ e $Z(X_i + h)$, separados por uma distância h .

TABELA 3 – MODELOS TEÓRICOS DE SEMIVARIOGRAMAS.

| Modelo | Equação | Condição |
|-------------|--|-----------------|
| Esférico | $\gamma(h) = C_0 + C \left[1,5 \left(\frac{h}{a} \right) - 0,5 \left(\frac{h}{a} \right)^3 \right]$ | para $h < a$ |
| | $\gamma(h) = C_0 + C$ | para $h \geq a$ |
| Exponencial | $\gamma(h) = C_0 + C \left[1 - \exp \left(-\frac{h}{a} \right) \right]$ | para $h < a$ |
| | $\gamma(h) = C_0 + C$ | para $h \geq a$ |

| | | | |
|---------------|---|-----------------|------|
| Gaussiano | $\gamma(h) = C_0 + C \left[1 - \exp \left(-\frac{h^2}{a^2} \right) \right]$ | para $h < a$ | (11) |
| | $\gamma(h) = C_0 + C$ | para $h \geq a$ | |
| Pentaesférico | $\gamma(h) = C_0 + C \left[\frac{15}{8} \left(\frac{h}{a} \right) - \frac{5}{4} \left(\frac{h}{a} \right)^3 + \frac{3}{8} \left(\frac{h}{a} \right)^5 \right]$ | para $h < a$ | (12) |
| | $\gamma(h) = C_0 + C$ | para $h \geq a$ | |
| Circular | $\gamma(h) = C_0 + C \left[7 \left(\frac{h}{a} \right) - \frac{35}{4} \left(\frac{h}{a} \right)^3 + \frac{7}{2} \left(\frac{h}{a} \right)^5 - \frac{3}{4} \left(\frac{h}{a} \right)^7 \right]$ | para $h < a$ | (13) |
| | $\gamma(h) = C_0 + C$ | para $h \geq a$ | |

Em que: $\gamma(h)$ = semivariância; C_0 = efeito pepita; $C_0 + C$ = patamar; a = alcance; e h = distância.
 FONTE: Yamamoto e Landim (2013).

Os semivariogramas foram determinados nas direções de 0°, 45°, 90° e 135° para verificar a presença de anisotropia, em que, caso detectada, o ângulo da anisotropia foi ajustado para a obtenção de um modelo semivariográfico com parâmetros comuns (efeito pepita, patamar e alcance) em todas as direções (YAMAMOTO; LANDIM, 2013). O melhor ajuste foi selecionado com base na menor soma de quadrados dos desvios ponderados (SQDP), no maior coeficiente de determinação (R^2) e na validação cruzada.

3.5.2 Interpolação espacial

A interpolação espacial consistiu na utilização das unidades amostrais com valores conhecidos para estimar, por meio dos semivariogramas teóricos ajustados, os valores em locais não amostrados das variáveis do povoamento. Para isso, a interpolação e a espacialização das variáveis do povoamento foram efetuadas pelos métodos univariados de krigagem simples e krigagem ordinária, bem como pelos métodos multivariados de cokrigagem ordinária e krigagem com deriva externa, considerando as variáveis de sensoriamento remoto como covariáveis nas estimações no espaço.

3.5.2.1 Krigagem simples

Na krigagem simples ou estacionária (14), a estimativa de uma variável em um local não amostrado $\hat{z}_{SK}(x_0)$ é dada por uma soma linear, a qual incorpora a média do processo (μ) e que deve ser estacionária de segunda ordem, ou seja, com média

e variância constantes. A soma dos pesos (λ_i) não é limitada a 1, em que a ausência de viés é garantida pela inclusão do termo à direita da equação (WEBSTER; OLIVER, 2007).

$$\hat{Z}_{KS}(x_0) = \sum_{i=1}^N \lambda_i Z(x_i) + (1 - \sum_{i=1}^N \lambda_i) \mu \quad (14)$$

O método da krigagem simples supõe que a média do fenômeno em estudo (μ) seja conhecida e constante no espaço amostral. Apesar desse pressuposto nem sempre ser verdadeiro, faz-se necessário utilizar a média da amostra como a melhor informação ou, também, estimá-la considerando a vizinhança mais próxima de uma região (YAMAMOTO; LANDIM, 2013). Dessa forma, para estimação do parâmetro μ , utilizou-se a média amostral das variáveis do povoamento.

3.5.2.2 Krigagem ordinária

Na krigagem ordinária (15), a estimativa em um ponto não amostrado resulta da combinação dos valores encontrados na vizinhança próxima (YAMAMOTO; LANDIM, 2013), cuja média é desconhecida. Nesse método, os pesos (λ_i) são influenciados pelo semivariograma teórico ajustado, considerando as distâncias entre os pontos amostrais $Z(x_i)$ e o ponto a ser estimado $\hat{Z}_{KO}(x_0)$. Assim, pesos maiores são atribuídos aos pontos mais próximos, o que minimiza os efeitos de agrupamento ou redundância dos dados (BAGNARA et al., 2012).

$$\hat{Z}_{KO}(x_0) = \sum_{i=1}^N \lambda_i Z(x_i) \quad (15)$$

3.5.2.3 Cokrigagem ordinária

Quando a amostragem da variável de interesse é insuficiente e o objetivo é melhorar a sua estimativa, pode-se utilizar a correlação da variável principal com uma variável auxiliar (covariável) mais densamente amostrada (WATANABE et al., 2009; YAMAMOTO; LANDIM, 2013). Para isso, a cokrigagem ordinária é um dos principais

métodos, a qual requer o cálculo e a modelagem de semivariogramas cruzados (16).

$$\gamma_{1,2}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z_1(X_{1i}) - Z_1(X_{1i} + h)][Z_2(X_{2i}) - Z_2(X_{2i} + h)] \quad (16)$$

Em que: $\gamma_{1,2}(h)$ = semivariância da variável principal Z_1 e da covariável Z_2 ; h = distância; e $N(h)$ = número de pares de pontos medidos $Z_i(X_{ii})$ e $Z_i(X_{ii} + h)$, separados por uma distância h .

Pela cokrigagem ordinária (17), a estimativa da variável principal em um local não amostrado $\hat{Z}_{CK_1}(x_0)$ é dada por uma combinação linear entre Z_1 e Z_2 , cujos pesos λ_1 e λ_2 são distribuídos conforme a dependência espacial de cada variável, bem como pela correlação cruzada entre elas. Contudo, deve-se averiguar a existência de algum nível de correlação entre a variável principal e a covariável (YAMAMOTO; LANDIM, 2013).

$$\hat{Z}_{CK_1}(x_0) = \sum_{i=1}^{N_1} \lambda_{1i} Z_1(x_{1i}) + \sum_{i=1}^{N_2} \lambda_{2i} Z_2(x_{2i}) \quad (17)$$

3.5.2.4 Krigagem com deriva externa

A krigagem com deriva externa, ou krigagem universal, é um método que permite estimar uma variável considerando as informações de uma covariável conhecida em todo o espaço (WACKERNAGEL, 1995). Assim, considerando $Z_1(x)$ como a variável primária e $Z_2(x)$ como a covariável, pode-se descrever essa correlação por meio de uma relação linear (18). Isso indica que a variabilidade espacial da variável secundária $Z_2(x)$ está relacionada às tendências locais $Z_1(x)$.

$$E[Z_1(x)] = \beta_0 + \beta_1 Z_2(x) + \hat{\varepsilon} \quad (18)$$

Na krigagem com deriva externa, o componente fixo $\beta_0 + \beta_1 Z_2(x)$ é separado do componente aleatório $\hat{\varepsilon}$. Com isso, considera-se que a tendência na variável principal é uma função das coordenadas espaciais em uma classe de modelos lineares mistos. Assim, essas coordenadas são substituídas pelos valores de uma ou

mais covariáveis $Z_2(x)$, ou variáveis ‘externas’, nos locais onde a principal $Z_1(x)$ será estimada, bastando determinar os parâmetros β_i . O estimador (19) da krigagem com deriva externa $\hat{Z}_{KDE}(x_0)$ é dado por (WEBSTER; OLIVER, 2007):

$$Z_{KDE}^*(x_0) = \sum_{i=1}^N \lambda_i Z(x_i) \quad (19)$$

3.5.3 Avaliação dos métodos de krigagem

As estimativas pelos métodos de krigagem foram comparados com os valores observados das variáveis do povoamento nos pontos amostrados. Para isso, a validação cruzada por *leave-one-out* foi aplicada com o auxílio do pacote *gstat* (PEBESMA, 2004), bem como as estatísticas: *BIAS* – viés (20), *MAE* – erro médio absoluto (21) e *MPE* – em porcentagem (22), *RMSE* – raiz quadrada do erro médio quadrático absoluto (23) e *RMSE%* – em porcentagem (24) e $r_{\hat{x}x}$ – correlação linear simples de Pearson entre os valores observados e estimados.

$$BIAS = x_i - \hat{x} \quad (20)$$

$$MAE = \frac{\sum |x_i - \hat{x}|}{n} \quad (21)$$

$$MPE = \frac{MAE}{\bar{x}} 100 \quad (22)$$

$$RMSE = \sqrt{\frac{\sum (x_i - \hat{x})^2}{n}} \quad (23)$$

$$RMSE\% = \frac{RMSE}{\bar{x}} 100 \quad (24)$$

4 RESULTADOS E DISCUSSÃO

4.1 ANÁLISE EXPLORATÓRIA DAS VARIÁVEIS DO POVOAMENTO

As variáveis derivadas diretamente das medidas de diâmetro (\bar{d} , d_g e d_{dom}) e de altura (\bar{h} e h_{dom}) apresentaram os menores valores de coeficientes de variação ($cv\%$) (TABELA 4). Por outro lado, maiores $cv\%$ foram observados para as variáveis volume (V) e área basal (G), principalmente para V , sendo essa decorrente da combinação das variáveis diâmetro, altura e forma, o que justifica a sua maior variabilidade.

TABELA 4 - ANÁLISE ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS DO POVOAMENTO DE TECA.

| Variável | Mínimo | Média | Máximo | Desvio padrão | $cv\%$ | Anderson-Darling |
|-----------------------|--------|--------|--------|---------------|--------|--------------------|
| V ($m^3 ha^{-1}$) | 162,00 | 394,29 | 536,64 | 81,66 | 20,71 | 1,33* |
| G ($m^2 ha^{-1}$) | 21,35 | 39,93 | 50,66 | 6,11 | 15,30 | 1,37* |
| \bar{d} (cm) | 26,49 | 33,10 | 38,29 | 2,78 | 8,40 | 0,63 ^{ns} |
| d_g (cm) | 26,23 | 34,80 | 41,62 | 3,26 | 9,38 | 0,45 ^{ns} |
| d_{dom} (cm) | 32,95 | 39,59 | 48,46 | 3,62 | 9,15 | 0,15 ^{ns} |
| \bar{h} (m) | 19,60 | 25,75 | 29,10 | 2,39 | 9,29 | 2,60* |
| h_{dom} (m) | 20,84 | 27,73 | 31,78 | 2,40 | 8,67 | 0,79* |

^{ns} = não significativo (há distribuição normal); e * = significativo a 5% pelo teste de Anderson-Darling (não há distribuição normal).

FONTE: O autor (2020).

Todavia, a baixa variabilidade observada é um indicativo de maior homogeneidade dos dados, o que pode ser resultado dos desbastes aplicados no povoamento. Os desbastes tendem a alterar a estrutura dos plantios, especialmente os seletivos ao remover os indivíduos de menor porte e com adversidades fitossanitárias e/ou de qualidade, como tortuosidade e bifurcação (OLIVEIRA et al., 1998; CALDEIRA; OLIVEIRA, 2008; 2016; CAMPOS; LEITE, 2017). Esse resultado também é demonstrado pela baixa amplitude dos dados, considerando as diferenças entre os valores mínimos e máximos das variáveis (TABELA 4).

Por meio do teste de Anderson-Darling (TABELA 4), verificou-se normalidade dos dados para as variáveis média aritmética dos diâmetros (\bar{d}), diâmetro médio quadrático (d_g) e diâmetro dominante (d_{dom}). Para as demais, a ausência de aderência entre as distribuições observadas e a teórica Normal evidenciou a não-

normalidade ao nível de 5% de significância.

Os resultados a respeito da ausência ou presença de normalidade dos dados também podem ser evidenciados nas distribuições de densidade (FIGURA 3). Com isso, a presença de distribuições unimodais com baixa assimetria para as variáveis \bar{d} , d_g e d_{dom} corroborou a presença de normalidade pelo teste de Anderson-Darling ao nível de 5% de significância (TABELA 4).

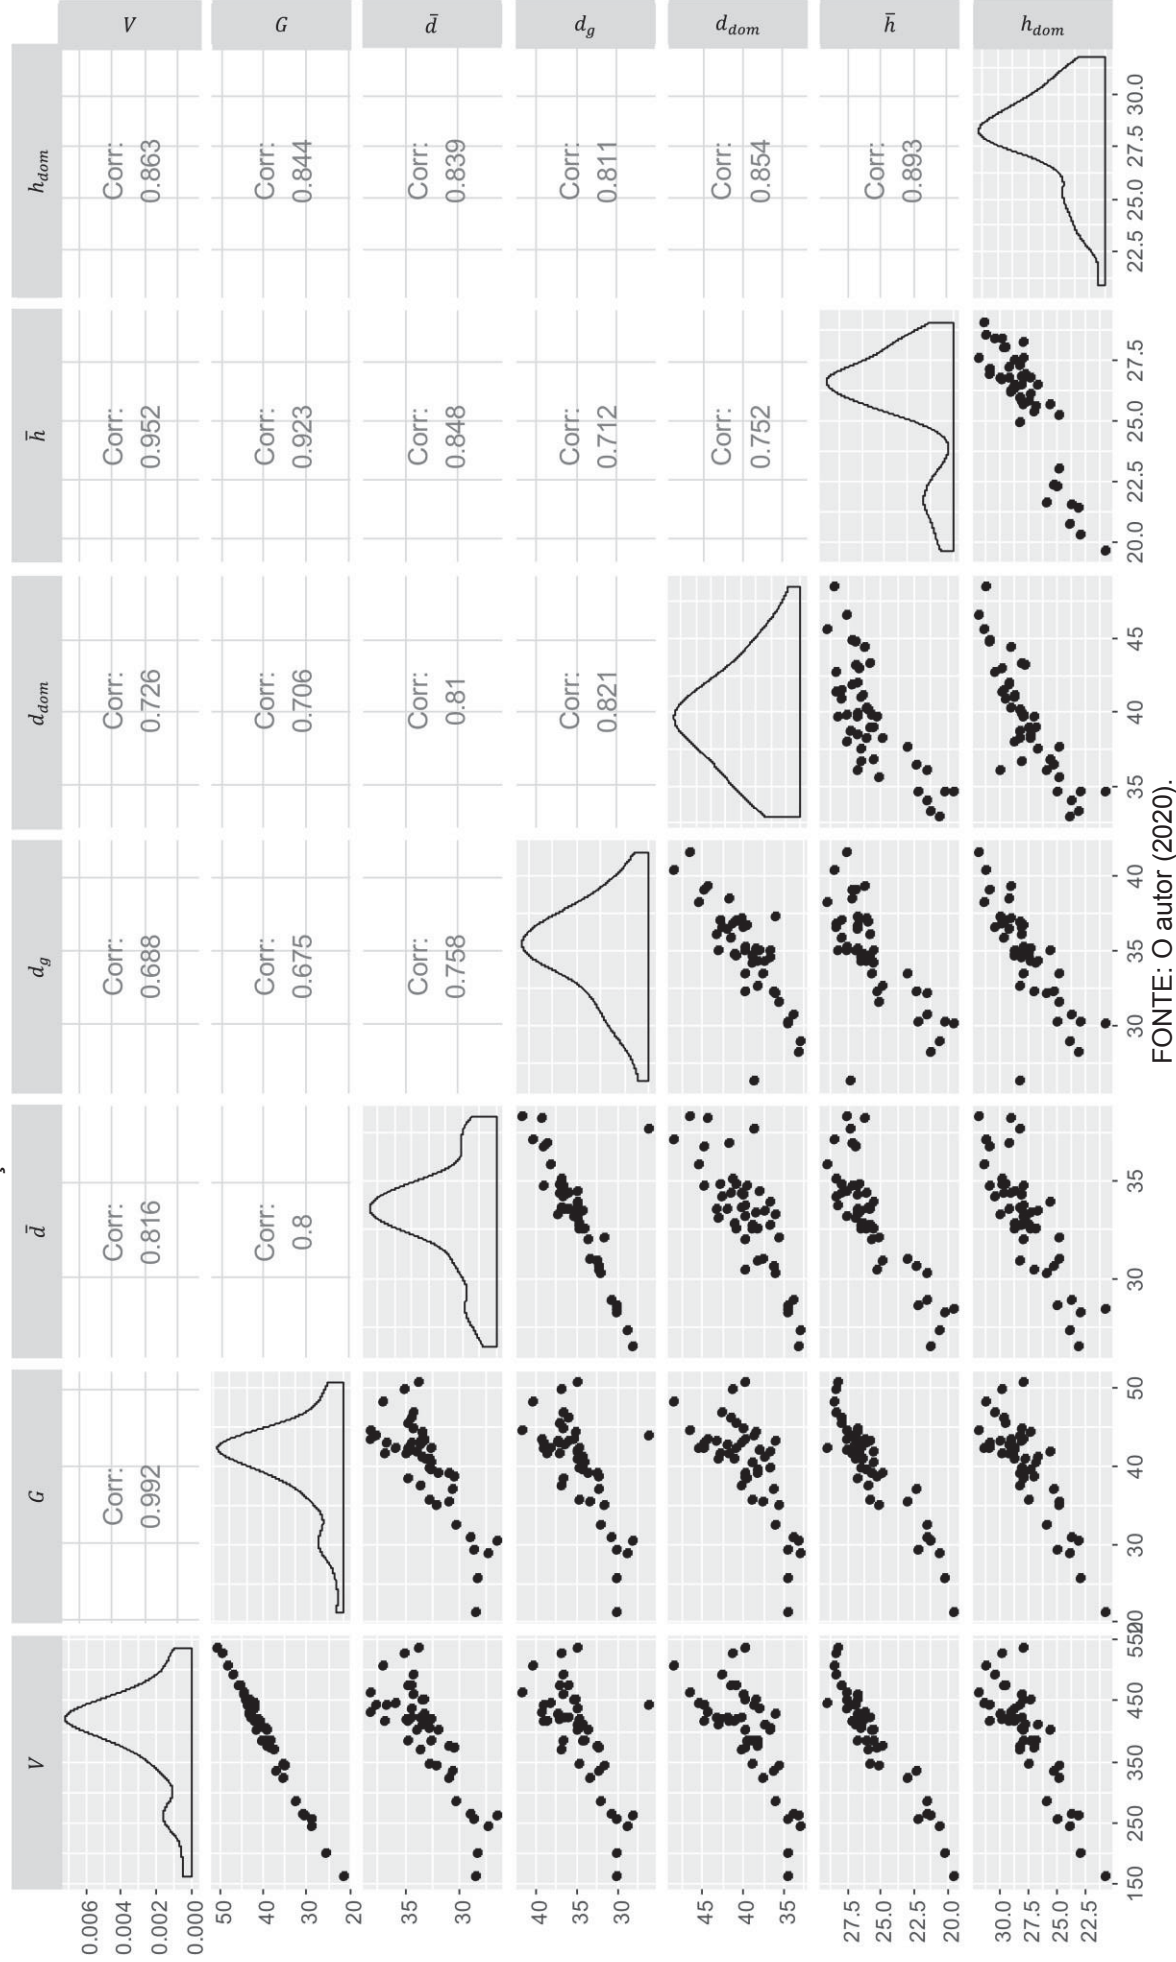
A presença de distribuições assimétricas negativas (à esquerda) foi observada para as variáveis volume (V) e área basal (G), em que houve o deslocamento da classe de maior frequência (moda) à direita da distribuição (FIGURA 3). Isso também é uma evidência das alterações proporcionadas pelos desbastes em povoamentos florestais de longa rotação, o que também foi observado por Nogueira et al. (2006), que avaliaram um modelo de distribuição diamétrica ajustado para povoamentos de teca submetidos a desbaste.

Além disso, também em decorrência dos sucessivos desbastes aplicados no povoamento, as distribuições das variáveis média aritmética das alturas (\bar{h}) e altura dominante (h_{dom}) apresentaram comportamentos semelhantes (FIGURA 3), uma vez que a estrutura do plantio foi simplificada, de modo geral, aos indivíduos de maior dominância. Ademais, a tendência de distribuições bimodais (FIGURA 3) para essas duas variáveis pode indicar a existência de ao menos duas classes de sítios com produtividades distintas.

Apesar da normalidade dos dados não ser uma suposição à aplicação das análises geoestatísticas, a presença de assimetria pode ser prejudicial, devido ao peso que poucas observações podem exercer no processo de estimação em locais não amostrados (YAMAMOTO; LANDIM, 2013). Por isso, no presente estudo, optou-se pela transformação logarítmica das variáveis do povoamento, visando reduzir a assimetria de suas distribuições.

Ademais, as dispersões dos dados observados e as correlações evidenciaram as dependências lineares entre as variáveis do povoamento (FIGURA 3). Com isso, a maior correlação foi observada entre o volume (V) e a área basal (G), mostrando a maior influência do diâmetro na forma quadrática para determinação dos volumes (HUSCH et al., 2003; MIGUEL et al., 2015).

FIGURA 3 – RELAÇÕES ENTRE AS VARIÁVEIS DO POVOAMENTO DE TECA.



4.2 ANÁLISE EXPLORATÓRIA DAS VARIÁVEIS DE SENSORIAMENTO REMOTO

As variáveis Índice de Vegetação da Diferença Normalizada (*NDVI*), Índice de Vegetação Melhorado (*EVI*), Índice de Vegetação Ajustado ao Solo (*SAVI*), Índice de Área Foliar (*IAF*), Índice de Vegetação Resistente a Atmosfera (*ARVI*), Componente Principal (*CP*) e Índice Brilho do Solo (*Brightness*) apresentaram os maiores valores do coeficiente de variação (*cv%*), variando de 31,6 a 43,5% (TABELA 5). Diante disso, é possível evidenciar que a *CP* se mostrou mais sensível as variações na cobertura vegetal da área de estudo, ao passo que o Índice de Vegetação Resistente à Atmosfera na Região do Visível (*VARI*) foi o menos sensível, com *cv%* de 15,5%.

TABELA 5 - ANÁLISE ESTATÍSTICA DESCRITIVA DAS VARIÁVEIS DE SENSORIAMENTO REMOTO EM POVOAMENTO DE TECA.

| Variável | Mínimo | Média | Máximo | Desvio padrão | <i>cv%</i> | Anderson-Darling |
|-------------------|--------|-------|--------|---------------|------------|------------------|
| <i>SR</i> | 0,00 | 2,18 | 5,70 | 0,52 | 23,89 | 24,73* |
| <i>NDVI</i> | -1,00 | 0,35 | 0,70 | 0,13 | 36,42 | 258,55* |
| <i>EVI</i> | -0,47 | 0,28 | 0,69 | 0,11 | 39,05 | 70,07* |
| <i>SAVI</i> | -1,48 | 0,52 | 1,04 | 0,19 | 36,45 | 256,64* |
| <i>ARVI</i> | -1,00 | 0,66 | 1,43 | 0,21 | 31,58 | 192,19* |
| <i>VARI</i> | -0,10 | 0,79 | 1,29 | 0,12 | 15,49 | 144,50* |
| <i>IAF</i> | -1,28 | 0,83 | 2,23 | 0,32 | 38,62 | 73,36* |
| <i>CP</i> | 13 | 61,76 | 336 | 26,84 | 43,46 | 975,57* |
| <i>Brightness</i> | 12,72 | 56,48 | 303,16 | 23,94 | 42,40 | 970,32* |
| <i>Greenness</i> | -95,35 | -2,72 | 13,69 | 6,16 | -226,18 | 844,42* |
| <i>Wetness</i> | -67,81 | -3,32 | 10,19 | 6,16 | -185,53 | 491,70* |

Em que: * = significativo a 5% pelo teste de Anderson-Darling; e ^{ns} = não significativo (há distribuição normal).

FONTE: O autor (2020).

Com o teste de Anderson-Darling foi observada a ausência de normalidade para as variáveis de sensoriamento remoto ao nível de 5% de significância (TABELA 5). Porém, a transformação logarítmica não foi aplicada, uma vez que alguns índices apresentaram valores negativos.

Ao avaliar os diagramas de dispersão entre as variáveis de sensoriamento remoto (FIGURA 4), observou-se distribuições unimodais com pouca assimetria para o Índice de Razão Simples (*SR*), *NDVI*, *EVI*, *SAVI*, *ARVI*, *VARI* e *IAF*. Além disso, a forte dependência linear entre essas variáveis é evidenciada pela menor dispersão

das observações, uma vez que elas, de modo geral, são derivadas das mesmas informações, como a reflectância nas bandas infravermelho próximo (*NIR*) e vermelho (*RED*).


No caso das outras variáveis, *CP* e *Brightness* apresentaram forte dependência linear e distribuição com assimetria positiva, enquanto *Greenness* e *Wetness* exibiram correlação alta e assimetria negativa (FIGURA 4). Essas quatro variáveis também apresentaram diversos valores discrepantes, indicando possíveis *outliers*.

Neste estudo, o *IAF* estimado pelo modelo proposto por Duchemin et al. (2006) apresentou uma amplitude alta para a grandeza dessa variável, com valores mínimo e máximo de -1,28 e 2,23, respectivamente (TABELA 5). Esse padrão é esperado, tendo em vista que o modelo aplicado é subproduto do índice de vegetação *NDVI*, que apresentou desempenho semelhante.

A partir da realização da matemática de bandas do espectro eletromagnético, foi possível compor os mapas temáticos dos índices de vegetação (FIGURA 5). Assim, observou-se que as áreas com coloração verde indicaram valores de índices de vegetação elevados, sendo locais com alto vigor vegetativo. Por outro lado, as áreas de cores vermelho, laranja e amarelo evidenciaram áreas com baixo vigor vegetativo e, conseqüentemente, menores valores de índice de vegetação foram obtidos. Assim, foi possível diferenciar os locais com vegetação densa e volumosa das áreas de vegetação escassa e solo exposto. Esse comportamento foi inverso para as variáveis *CP* (FIGURA 5g) e *Brightness* (FIGURA 5h).

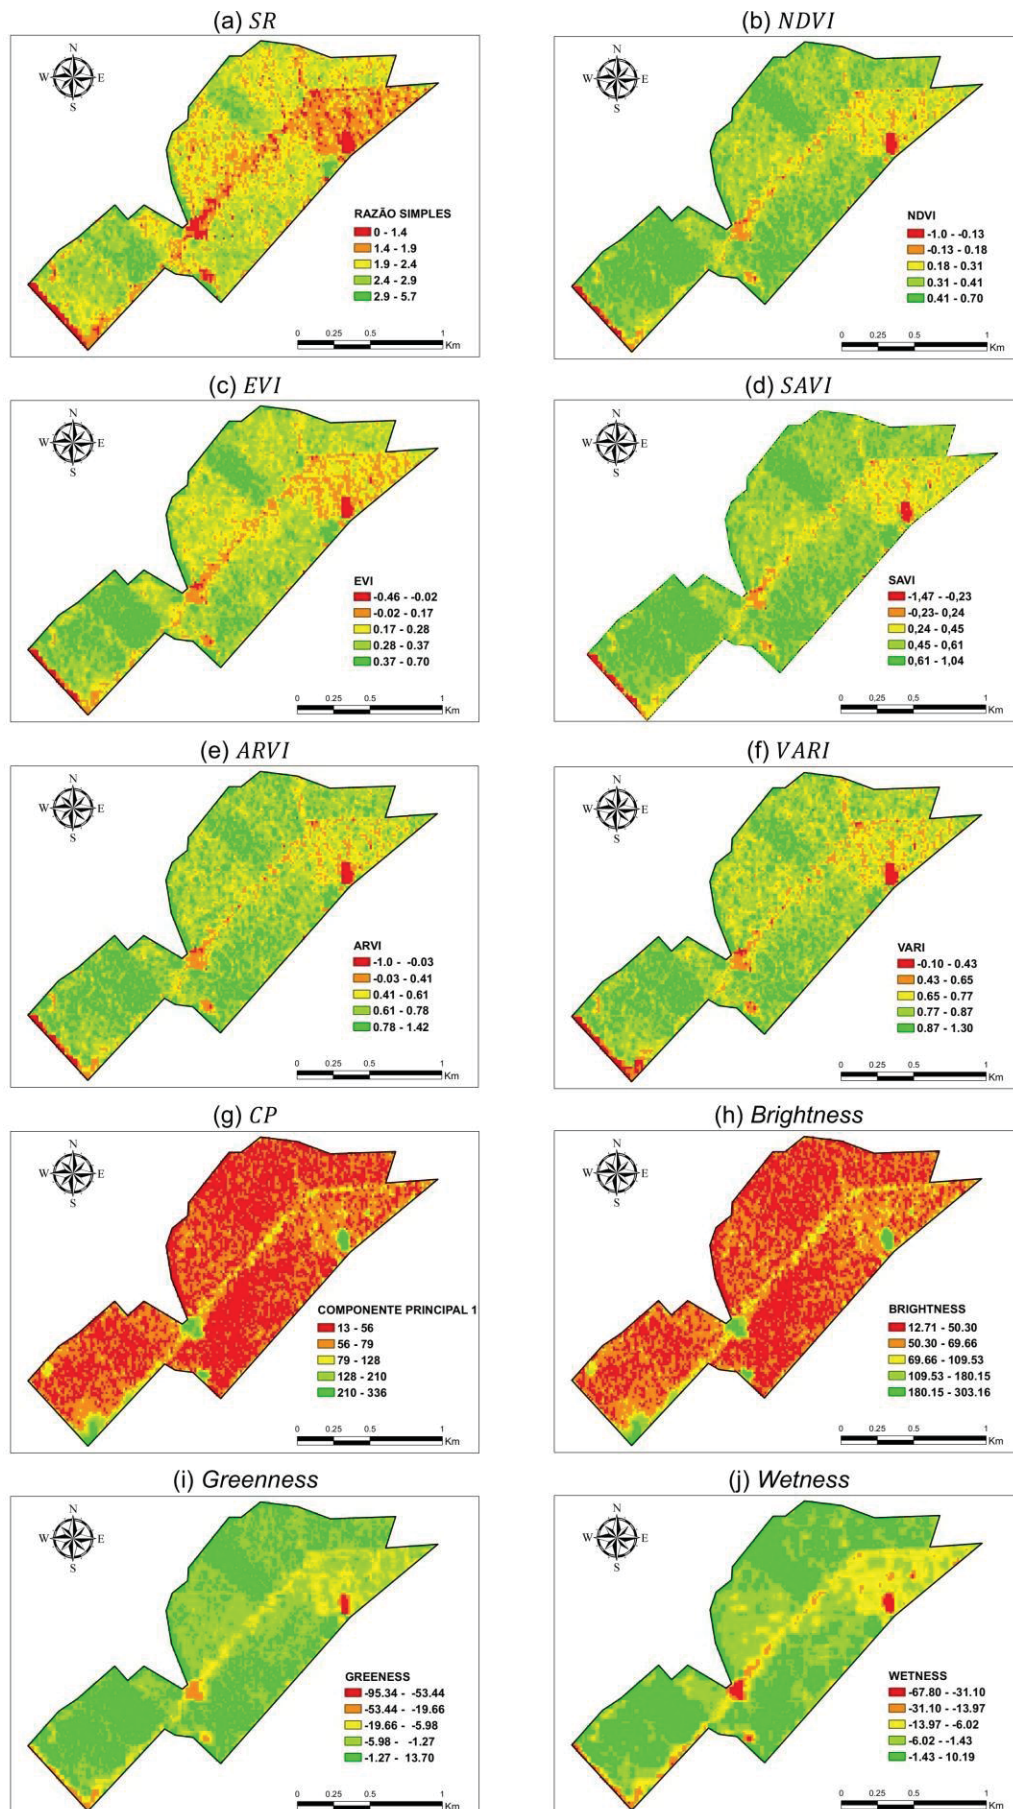
A faixa linear no centro do plantio (FIGURA 5) representou a presença de um aceiro e, por isso, valores baixos dos índices de vegetação foram obtidos devido a maior exposição do solo. Ademais, desde a implantação do povoamento, seis desbastes seletivos foram executados, com a diminuição considerável da densidade inicial de 1.111 árvores ha⁻¹ para 139 árvores ha⁻¹ em média. No presente estudo, essa densidade final variou de 89 árvores ha⁻¹ a 189 árvores ha⁻¹, em que os valores menores das variáveis de sensoriamento remoto também indicaram os locais com vegetação menos densa em decorrência dos desbastes mais intensos.

FIGURA 4 – RELAÇÕES ENTRE AS VARIÁVEIS DE SENSORIAMENTO REMOTO EM POVOAMENTO DE TECA.



FONTE: O autor (2020)

FIGURA 5 – MAPAS TEMÁTICOS DAS VARIÁVEIS DE SENSORIAMENTO REMOTO EM POVOAMENTO DE TECA.



FONTE: O autor (2020).

Para o Índice de Razão Simples (*SR*) os valores variaram de 0 a 5,70 na área do povoamento. Ao compará-lo com os demais índices, foi possível identificar uma frequência maior nas classes inferiores, caracterizadas pelas tonalidades amarela, laranja e vermelha no mapa temático (FIGURA 5a). Segundo Ponzoni et al, (2012) em florestas, a quantidade de radiação eletromagnética refletida, referente a região do vermelho, se aproxima de valores muito baixos e, por essa razão, o *SR* aumenta sem limites e diverge dos demais índices de vegetação.

Para o Índice de Vegetação da Diferença Normalizada (*NDVI*) gerado por meio da imagem Landsat 8 os valores variaram entre 0,7 e -1 (FIGURA 5b), sendo esse o índice de vegetação mais utilizado e intensamente estudado. Segundo Jensen (2009), o *NDVI* é altamente correlacionado com o Índice de Área Foliar (*IAF*), porém em períodos de máximo *IAF* essa relação pode não ser tão forte, aparentemente devido à saturação do *NDVI* que estabiliza em um patamar e torna-se insensível ao aumento de biomassa vegetal. Ressalta-se que a data de aquisição da imagem (março de 2018) coincide com a época de pleno enfolhamento da teca. Considerando que essa espécie possui um elevado grau de deciduidade foliar, a obtenção de imagens em períodos de desfolha ou início de reenfolhamento devem ser evitadas.

Observou-se que os valores em pontos de solo descoberto apresentaram valores baixos de *NDVI* e, por vezes, negativos. Segundo Huete e Tucker (1991), os valores do *NDVI* para solo exposto estão entre 0,05 e 0,30, no entanto, devido à grande variabilidade das propriedades óticas do solo, não se pode definir uma faixa rigorosa de *NDVI* para solos com pouca ou nenhuma cobertura vegetal.

O Índice de Vegetação Melhorado (*EVI*) é uma variável que apresenta um fator de ajuste para solos e dois coeficientes que descrevem o uso da banda azul para correção da banda vermelha quanto ao espalhamento atmosférico por aerossóis. Essas propriedades têm otimizado a sensibilidade para regiões de alta biomassa, permitindo o melhor monitoramento da estrutura e arquitetura do dossel e da fisionomia das plantas (JENSEN, 2009). Neste estudo, os valores de *EVI* variaram de -0,47 a 0,69 (FIGURA 5c).

A distribuição espacial do Índice de Vegetação Ajustado ao Solo (*SAVI*) na área de estudo está caracterizada na FIGURA 5d. O *SAVI* é uma adaptação do *NDVI*, porém, um fator de ajuste é utilizado para minimizar a contribuição do solo e, assim, destacar a resposta da vegetação (HUETE, 1988).

Uma vez que o Índice de Vegetação Resistente à Atmosfera na Região do Visível (*VARI*) é derivado do Índice de Vegetação Resistente à Atmosfera (*ARVI*), os

resultados dessas variáveis foram semelhantes no presente estudo (FIGURAS 5e-f), fato observado pela média dos valores de 0,79 e 0,66 (TABELA 5), respectivamente. O *VARI* apresentou o menor coeficiente de variação (*cv%*), caracterizando uma variabilidade menor para a área de estudo (TABELA 5).

A primeira Componente Principal (*CP*) explicou 97,3% da variabilidade total de informações da imagem original (TABELA 6). Por apresentar uma alta variância, uma vez que os valores de nível de cinza são bastante variáveis e distantes da média, a *CP* expressa grande heterogeneidade entre os alvos presentes e possibilita volume maior de informações sobre os alvos (ZANOTTA et al., 2019), o que permitiu gerar o mapa temático com alta variabilidade espacial (FIGURA 5g). Além disso, a presença de distribuição com forte assimetria positiva (FIGURA 4) acarretou em um mapa temático com tons de vermelho, em que as áreas com coloração verde corresponderam ao solo com menor ou ausência de cobertura vegetal.

TABELA 6 - ESTIMATIVAS DAS VARIÂNCIAS ASSOCIADAS AOS COMPONENTES PRINCIPAIS.

| Componente principal | Autovalor | Variância explicada (%) | Variância acumulada (%) |
|----------------------|-----------|-------------------------|-------------------------|
| 1 | 18173,52 | 97,30 | 97,30 |
| 2 | 303,47 | 1,62 | 98,90 |
| 3 | 137,20 | 0,73 | 99,63 |
| 4 | 59,13 | 0,31 | 99,95 |
| 5 | 6,41 | 0,03 | 99,98 |
| 6 | 1,80 | 0,01 | 99,99 |
| 7 | 0,73 | 0,004 | 100,00 |

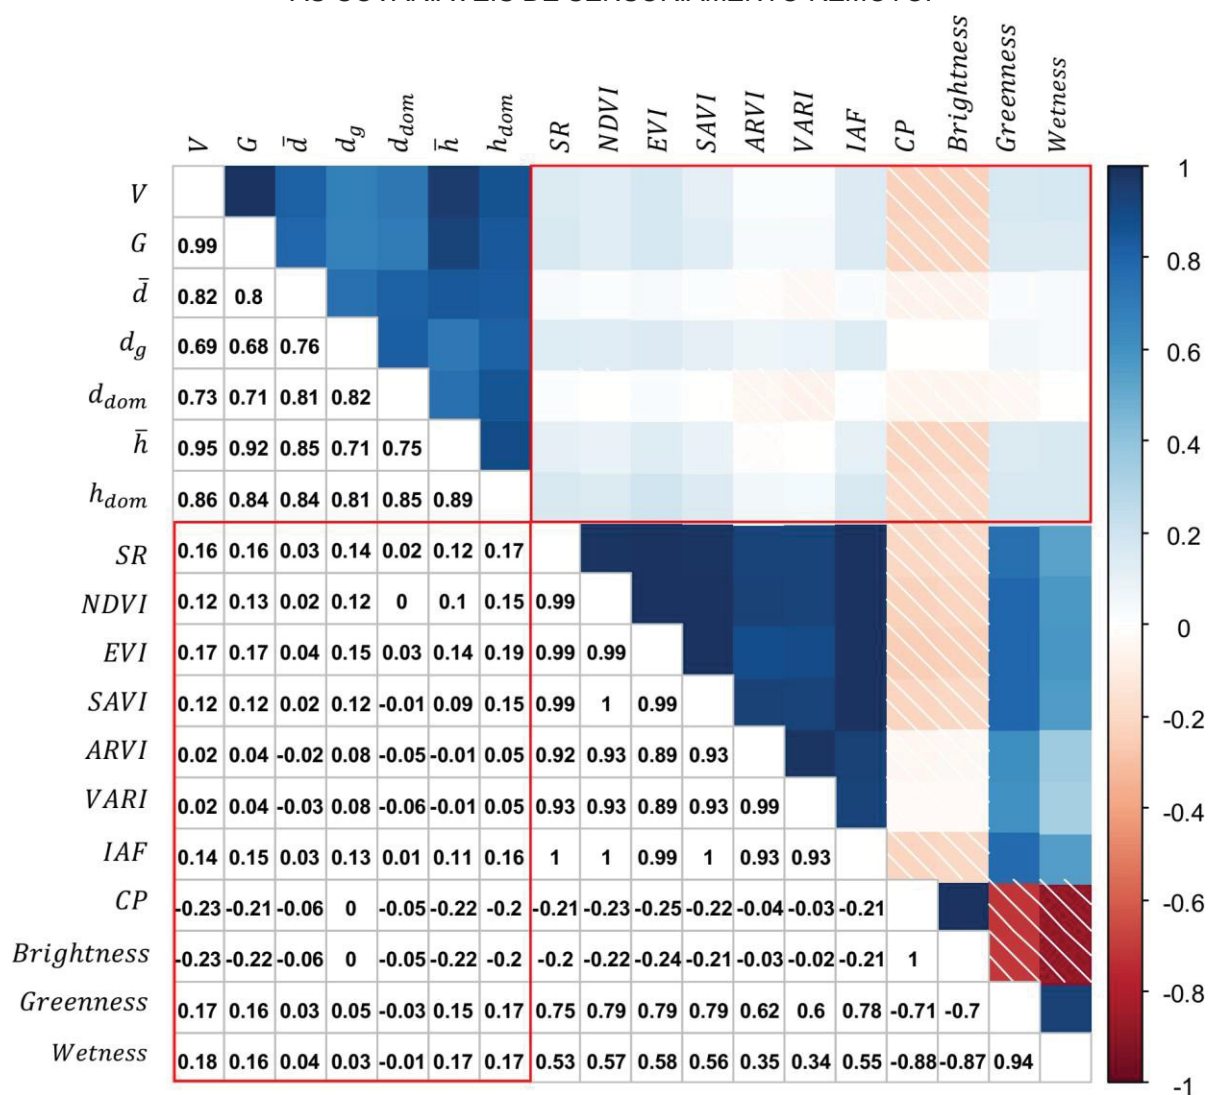
FONTE: O autor (2020).

A transformação *Tasseled Cap* possibilitou gerar os índices *Brightness*, *Greenness* e *Wetness*, sendo o *Brightness* correspondente a soma ponderada de todas as bandas e relacionado com a principal variação na reflectância do solo (FIGURA 5h). O *Greenness* representa o contraste entre o infravermelho próximo (banda 5) e as bandas visíveis, sendo, portanto, muito sensível à vegetação verde e sadia (FIGURA 5i). O *Wetness* é o indicador de umidade relacionado com a copa e a umidade do solo (FIGURA 5j), devido ao peso das bandas 6 e 7 (PHUA; SAITO, 2003).

4.3 RELAÇÕES ENTRE VARIÁVEIS DO POVOAMENTO E DE SENSORIAMENTO REMOTO

As variáveis do povoamento de teca apresentaram correlações lineares fracas (SCHÖBER et al., 2018) com as variáveis de sensoriamento remoto (FIGURA 6). Os maiores valores negativos foram observados entre V e \bar{h} com CP e $Brightness$, enquanto a maior correlação positiva ocorreu entre V com $Greenness$. Para d_g , não houve correlação com CP e $Brightness$.

FIGURA 6 – MATRIZ DE CORRELAÇÃO ENTRE AS VARIÁVEIS DO POVOAMENTO DE TECA E AS COVARIÁVEIS DE SENSORIAMENTO REMOTO.



FONTE: O autor (2020).

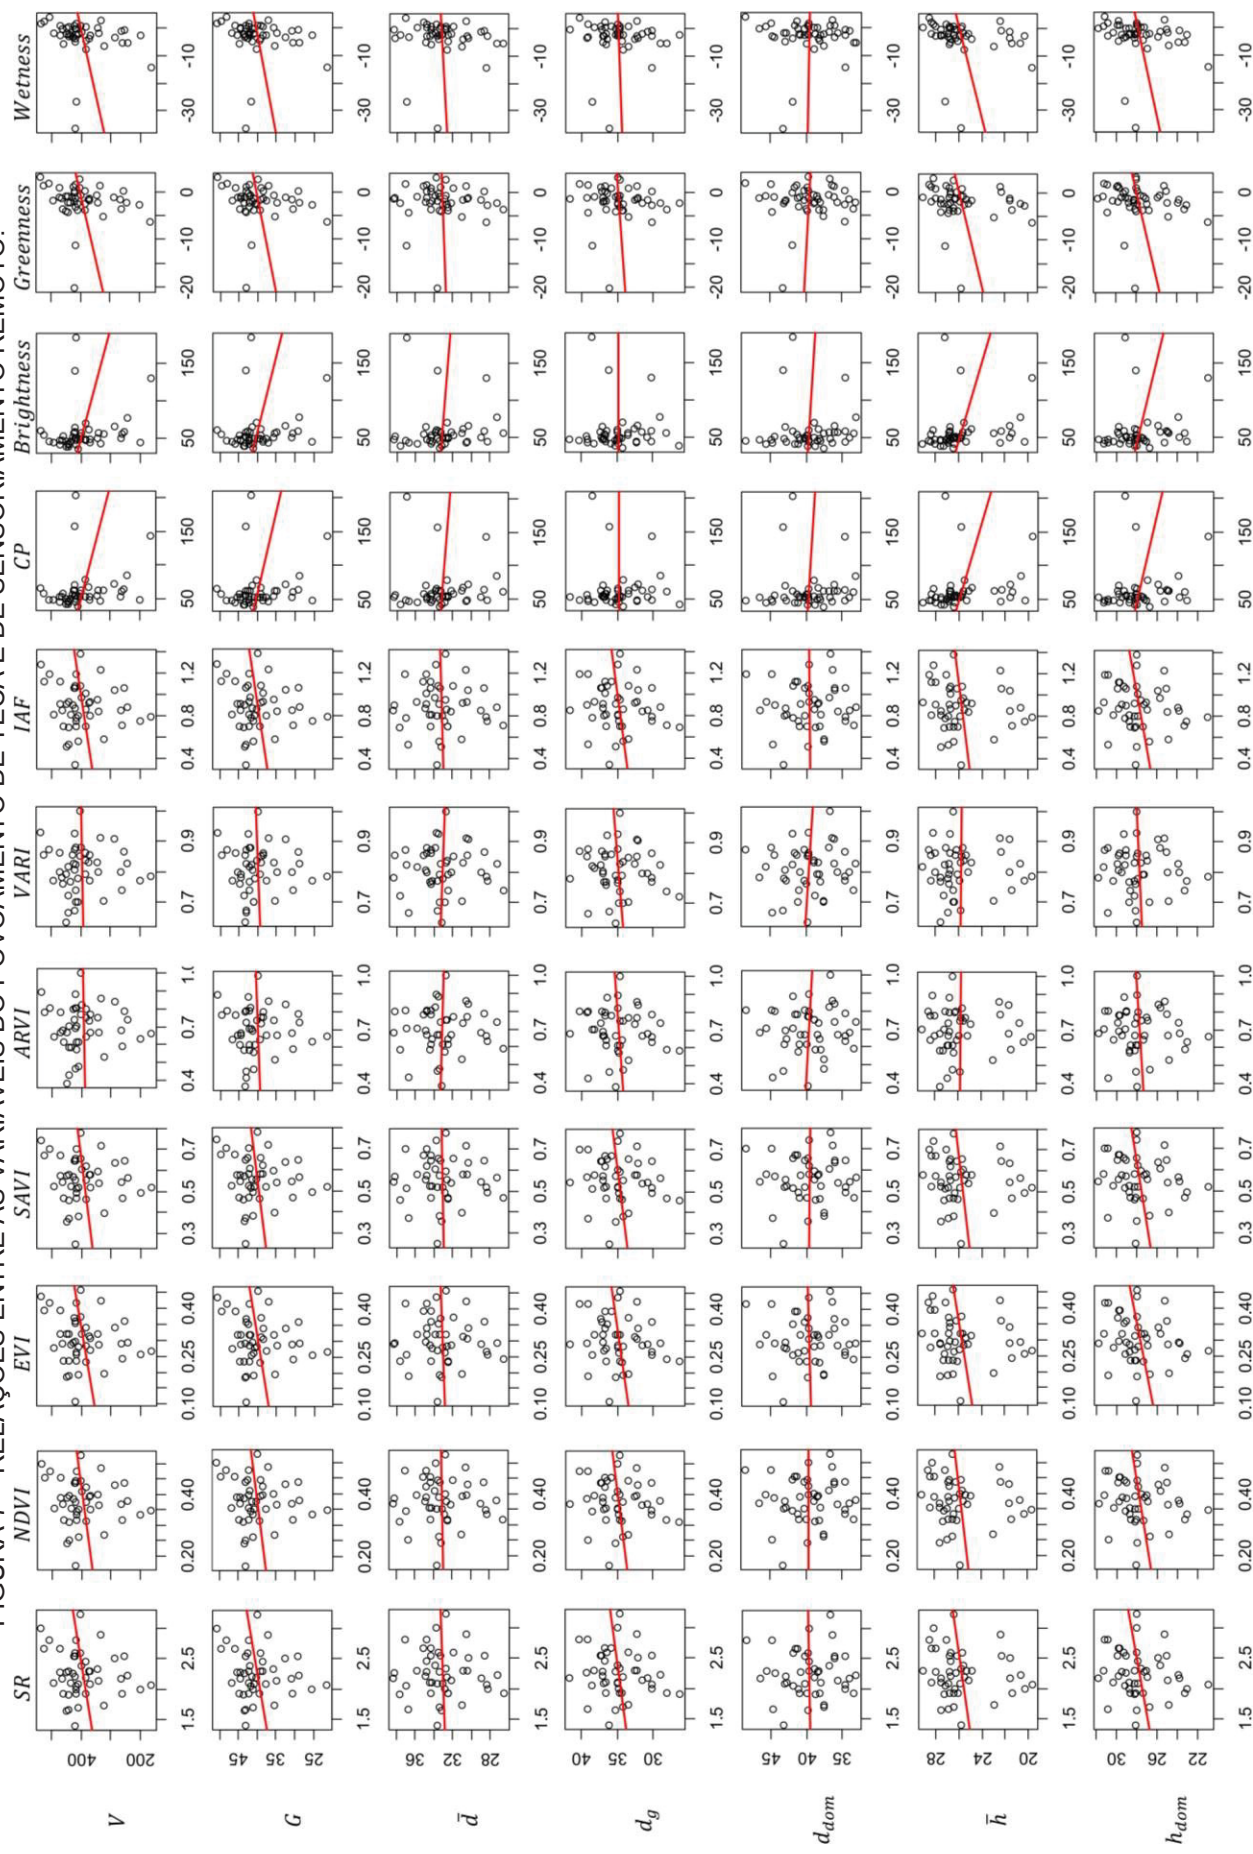
Nos diagramas de dispersão as relações lineares entre as variáveis do povoamento com as de sensoriamento remoto foram fracas (FIGURA 7). Houve tendência crescente mais evidente das variáveis V , G , d_g , \bar{h} e h_{dom} com SR , $NDVI$,

EVI, *SAVI*, *IAF*, *Greenness* e *Wetness*. Por outro lado, comportamento decrescente dessas variáveis do povoamento foram observadas com *CP* e *Brightness*, ao passo que, para *ARVI* e *VARI*, não houve relações aparentes.

Para \bar{d} e d_{dom} , todas as variáveis de sensoriamento remoto mostraram ausência de dependência linear (FIGURA 7), em que o aumento dos valores dos índices de vegetação não resultaram em alteração crescente ou decrescente dos valores médios de \bar{d} e d_{dom} . Ademais, a presença de valores extremos ficou evidenciada para *CP*, *Brightness*, *Greenness* e *Wetness*, o que tende a influenciar em suas correlações e relações lineares.

Esses resultados podem ser interpretados como a rejeição da hipótese formulada no presente trabalho, demonstrando que as variáveis de sensoriamento remoto, associadas como covariáveis nas modelagens geoestatística, não possibilitam prever as variáveis do povoamento de teca. Contudo, cabe salientar que se faz necessário avaliar também a dependência espacial para a completa avaliação. Segundo Ponzoni (2001), a falta de altas correlações entre variáveis dendrométricas e variáveis de sensoriamento remoto pode ser explicado pelo aspecto da cobertura vegetal gerada por uma imagem de satélite, que é consequência de um processo complexo que envolve muitos parâmetros e fatores ambientais. Desse modo, o que é medido por um sensor remotamente situado, proveniente de determinada vegetação, pode não ser explicado somente pelas características intrínsecas da vegetação, pois uma imagem sofre interferência de, por exemplo, efeitos da atmosfera, propriedades do dossel, fontes de radiação e solos.

FIGURA 7 – RELAÇÕES ENTRE AS VARIÁVEIS DO POVOAMENTO DE TECA E DE SENSORIAMENTO REMOTO.



FONTE: O autor (2020).

4.4 KRIGAGEM SIMPLES

Os parâmetros de ajustes do semivariograma efeito pepita (C_0), patamar ($C_0 + C$), alcance (a), assim como as estatísticas de ajuste coeficiente de determinação (R^2) e soma dos quadrados dos desvios ponderados (SQDP) estão apresentados na TABELA 7. Após os ajustes, as variáveis do povoamento apresentaram dependência espacial e predominância de melhores estatísticas com o modelo Esférico, exceto para o diâmetro dominante (d_{dom}), em que o modelo Exponencial foi selecionado como o estatisticamente melhor.

TABELA 7 – PARÂMETROS DOS SEMIVARIOGRAMAS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO DE TECA.

| Variáveis | Modelo | C_0 | $C_0 + C$ | a (m) | R^2 | SQDP |
|-----------|-------------|-------|-----------|---------|-------|------------------------|
| V | Esférico | 0,020 | 0,068 | 842 | 0,990 | $1,71 \times 10^{-8}$ |
| G | Esférico | 0,009 | 0,032 | 761 | 0,990 | $3,73 \times 10^{-9}$ |
| \bar{d} | Esférico | 0,002 | 0,008 | 913 | 0,950 | $6,33 \times 10^{-10}$ |
| d_g | Esférico | 0,004 | 0,010 | 881 | 0,802 | $4,02 \times 10^{-9}$ |
| d_{dom} | Exponencial | 0,000 | 0,009 | 222 | 0,943 | $4,81 \times 10^{-10}$ |
| \bar{h} | Esférico | 0,002 | 0,011 | 829 | 0,994 | $2,30 \times 10^{-10}$ |
| h_{dom} | Esférico | 0,002 | 0,009 | 800 | 0,992 | $1,49 \times 10^{-10}$ |

FONTE: O autor (2020).

O efeito pepita, que segundo Vieira (2000) e Carrasco (2010) representa a variância não explicada ocasionada frequentemente por erros ou variações não identificadas, apresentou valores baixos e inferiores a 0,020 e evidencia a qualidade estatística dos semivariogramas ajustados. Adicionalmente, os valores de alcance (a), que expressam as distâncias limites de dependência espacial entre as unidades amostrais (VIEIRA, 2000; CIGAGNA et al., 2015), apresentaram valores mínimo de 222 m para o diâmetro dominante (d_{dom}) e máximo de 913 m para o diâmetro médio (\bar{d}). Os demais ajustes resultaram em alcances (a) entre 761 m a 881 m, o que é indicativo da maior similaridade nas estruturas espaciais dessas variáveis.

Os coeficientes de determinação (R^2) dos ajustes, os quais indicam o quão próximo os valores reais das semivariâncias encontraram-se das estimativas, apresentaram valores superiores a 0,80 e indicaram elevada capacidade explicativa dos modelos selecionados para a variável de interesse. Ademais, as somas dos

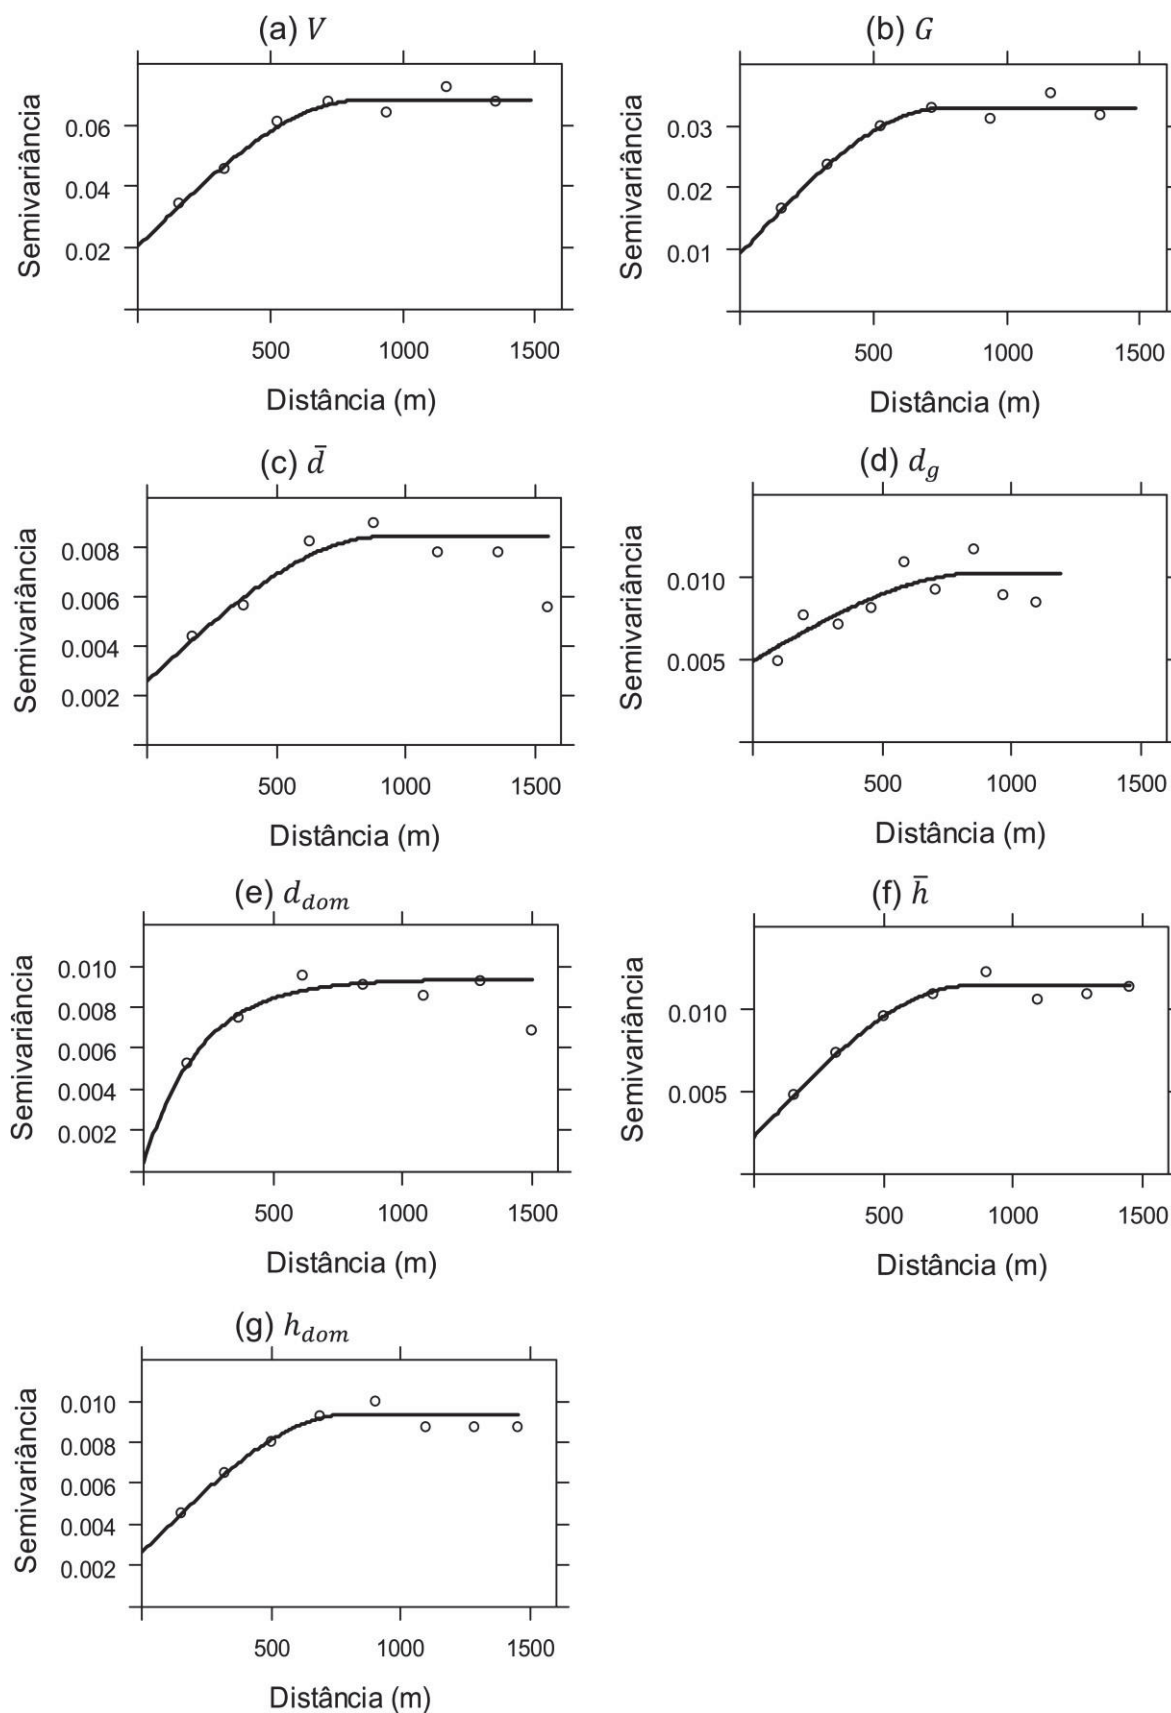
quadrados dos desvios ponderados (SQDP) resultaram em valores baixos, sendo o máximo de $6,33 \times 10^{-10}$ para a média aritmética dos diâmetros a 1,3 m do solo (\bar{d}).

A partir da análise gráfica dos semivariogramas (FIGURA 8), notou-se que as semivariâncias observadas apresentaram baixa dispersão em torno da linha média estimada para as variáveis do povoamento. Além disso, o comportamento crescente das semivariâncias estimadas e, posteriormente, estabilizado e constante em torno de uma distância máxima definida pelo parâmetro alcance (a) confirmaram a qualidade dos ajustes gerados.

Assim, após a obtenção dos ajustes e verificada a presença de dependência espacial entre as unidades amostrais, a interpolação espacial foi executada por meio da krigagem simples (FIGURA 9). Como resultados, mapas temáticos com padrões espaciais distintos e heterogêneos foram obtidos.

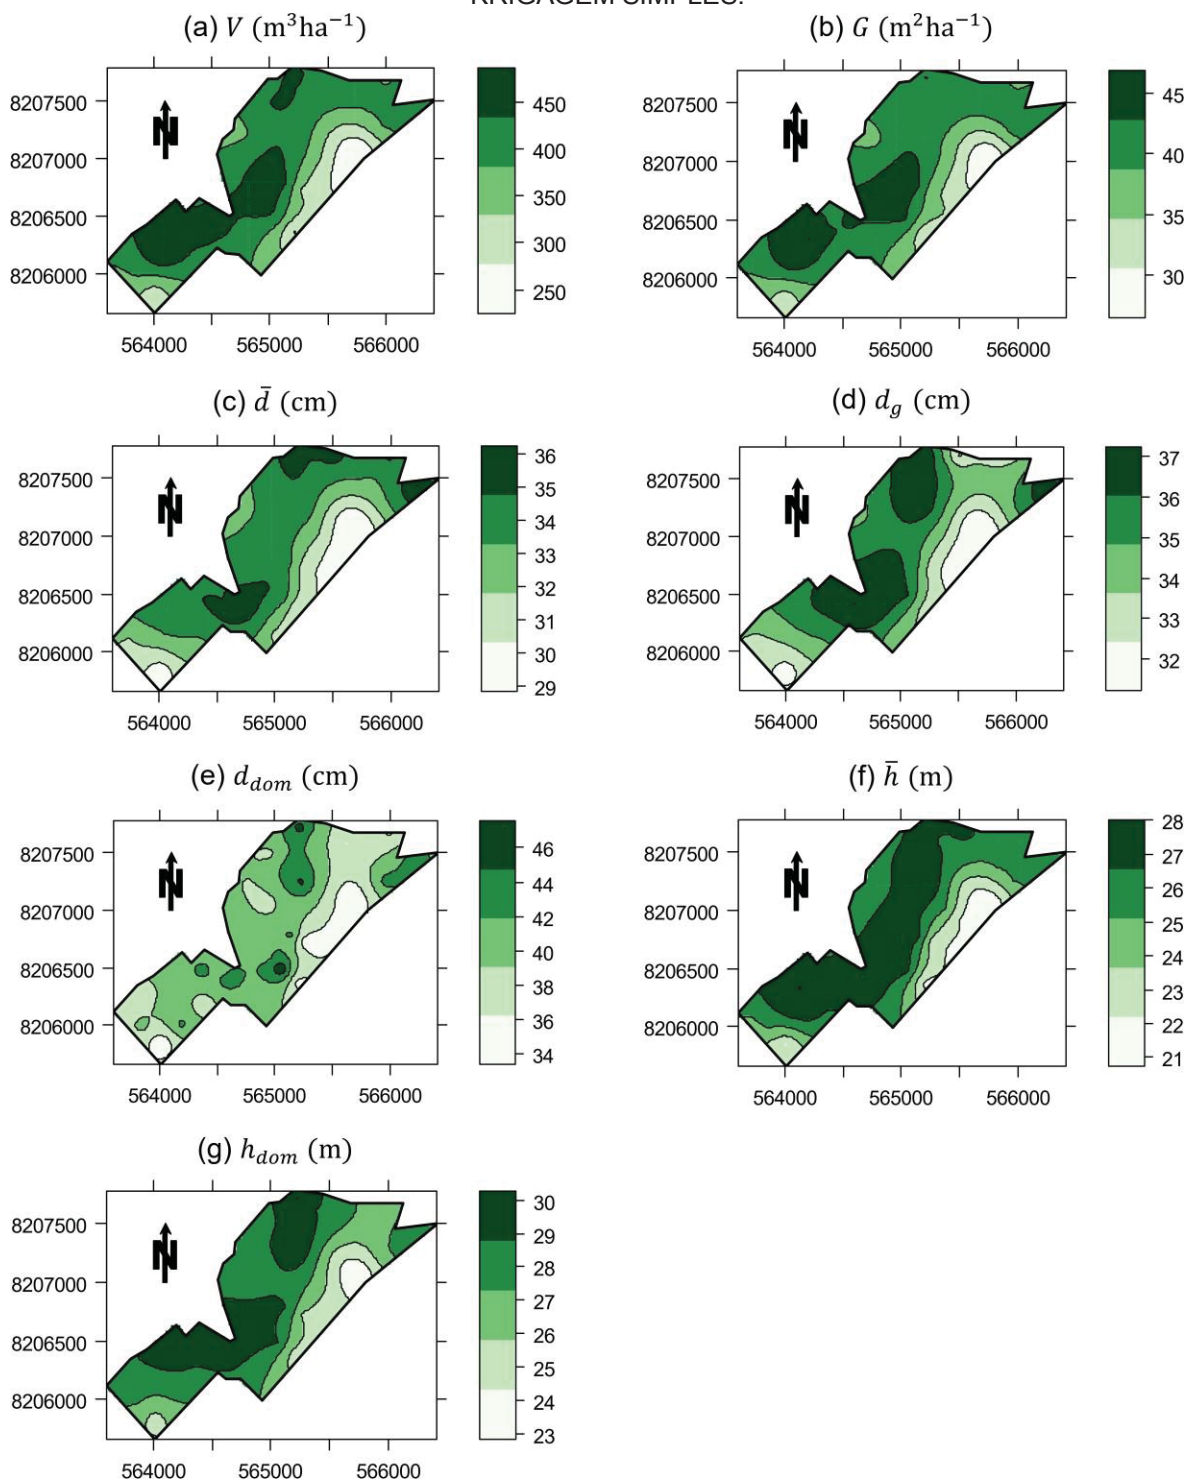
A região central dos mapas se destacou com os maiores valores de volume (V), área basal (G), diâmetro médio quadrático (d_g), média das alturas (\bar{h}) e altura dominante (h_{dom}). Ao contrário, a região Leste apresentou os menores valores para todas as variáveis do povoamento (FIGURA 9). Esses resultados possivelmente se devem a influência da qualidade de sítio, a qual é melhor nas áreas onde as variáveis do povoamento apresentaram valores maiores, o que pode ser comprovado pelo as maiores alturas dominantes presentes na mesma região (FIGURA 9g). Segundo Campos e Leite (2017), as áreas de alta capacidade produtiva são também aquelas cujo crescimento em altura dos indivíduos dominantes é elevado.

FIGURA 8 – SEMIVARIOGRAMAS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO DE TECA.



FONTE: O autor (2020).

FIGURA 9 – DISTRIBUIÇÃO ESPACIAL DAS VARIÁVEIS DO POVOAMENTO DE TECA POR KRIGAGEM SIMPLES.



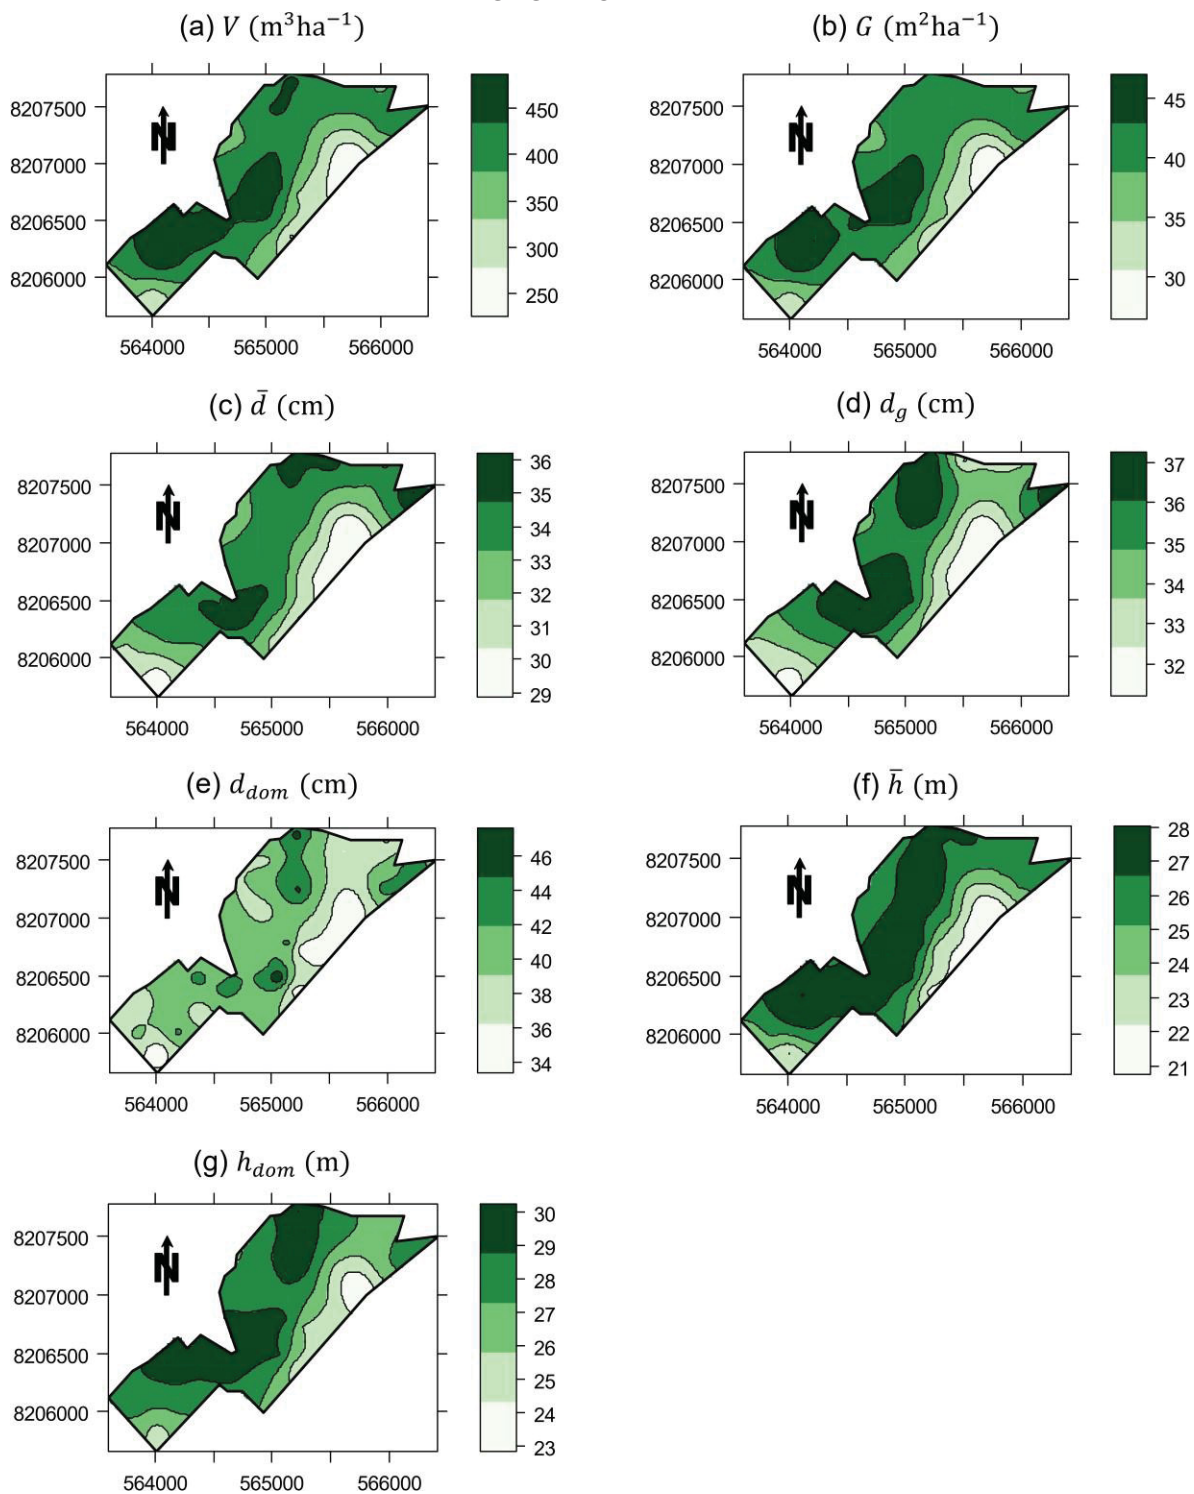
FONTE: O autor (2020).

Os mapeamentos também permitem definir que desbastes mais pesados sejam executados em locais com valores maiores de área basal (FIGURA 9b), regulando assim a produção volumétrica no plantio florestal.

4.5 KRIGAGEM ORDINÁRIA

Os mapas temáticos gerados pela krigagem ordinária (FIGURA 10) utilizaram os parâmetros dos semivariogramas empregados na krigagem simples (TABELA 7), os quais resultaram em padrões espaciais semelhantes, em que a região central apresentou os valores maiores para as variáveis do povoamento, enquanto na região Leste verificou-se valores menores.

FIGURA 10 – DISTRIBUIÇÃO ESPACIAL DAS VARIÁVEIS DO POVOAMENTO DE TECA POR KRIGAGEM ORDINÁRIA.



FONTE: O autor (2020).

4.6 COKRIGAGEM ORDINÁRIA

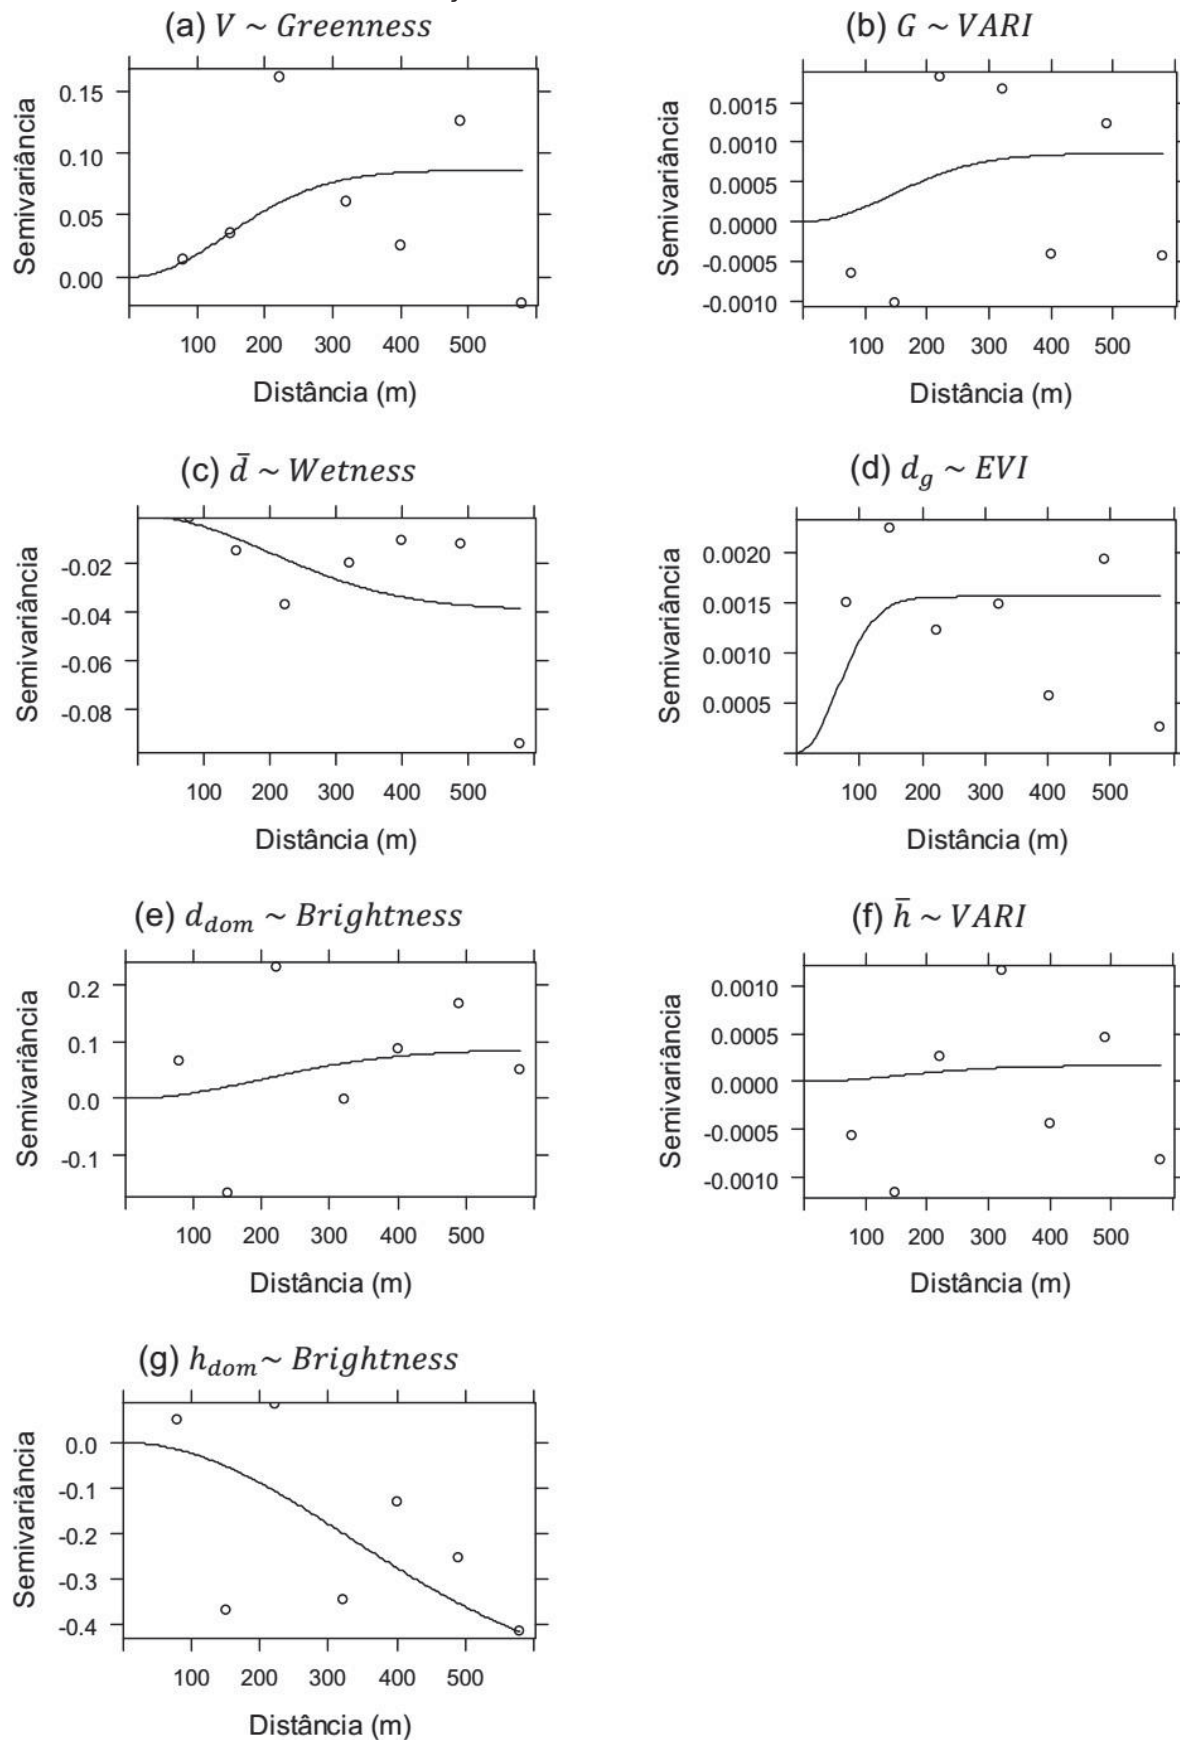
A cokrigagem ordinária visou relacionar uma variável principal com uma auxiliar, considerando a correlação espacial entre elas (YAMAMOTO; LANDIM, 2013). Contudo, para fins de apresentação dos resultados, optou-se por exibir os semivariogramas cruzados das variáveis do povoamento em relação as principais covariáveis de sensoriamento remoto selecionadas em sequência para a krigagem com deriva externa (FIGURA 11).

Esses semivariogramas cruzados apresentaram baixa qualidade de ajuste, com elevada dispersão das semivariâncias experimentais em torno de da linha média estimada (FIGURA 11). Comportamentos melhores não foram observados entre outras combinações de variáveis neste estudo. Isso provou que a cokrigagem ordinária não foi adequada para a predição dos padrões espaciais do povoamento de teca por meio de índices de sensoriamento remoto, cujos resultados também são evidência das baixas correlações observadas (FIGURA 6).

Na literatura, a cokrigagem ordinária é registrada como a mais adequada para relacionar variáveis de povoamentos florestais com atributos do solo, em que a correlação espacial é mais evidente. Como exemplo, as pesquisas desenvolvidas por Lima et al. (2010), os quais identificaram os atributos do solo que apresentaram maiores dependências linear e espacial com a produtividade de plantios de eucalipto; e Carvalho et al. (2012), que caracterizaram zonas específicas de manejo do solo, empregando correlações espaciais entre produtividade de madeira com atributos físico-químicos do solo.

Por outro lado, comportamentos relevantes foram observados nos semivariogramas cruzados, como a relação negativa entre as variáveis \bar{d} e *Wetness* (FIGURA 11c), bem como entre h_{dom} e *Brightness* (FIGURA 11g). Essa tendência inversa em um semivariograma cruzado indica que a correlação espacial entre essas variáveis, apesar de fraca, tende a ser negativa, em que o aumento de uma acarreta redução dos valores da outra (YAMAMOTO; LANDIM, 2013).

FIGURA 11 – SEMIVARIOGRAMAS CRUZADOS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO DE TECA EM FUNÇÃO DAS COVARIÁVEIS DE SENSORIAMENTO REMOTO.



FONTE: O autor (2020).

4.7 KRIGAGEM COM DERIVA EXTERNA

Assim como nos demais métodos, a abordagem da krigagem com deriva externa iniciou-se com a calibração dos parâmetros do semivariogramas (TABELA 8). A diferença nesse método de interpolação geoestatística deve-se à incorporação de variáveis auxiliares que possuem a capacidade de explicar parte da variabilidade principal (YAMAMOTO; LANDIM, 2013).

TABELA 8 – PARÂMETROS DOS SEMIVARIOGRAMAS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO DE TECA.

| Covariável | Modelo | C_0 | $C_0 + C$ | a (m) | R^2 | SQDP |
|---|----------|-------|-----------|---------|-------|-----------------------|
| <i>V</i> – volume do povoamento ($m^3 ha^{-1}$) | | | | | | |
| <i>NDVI</i> | Esférico | 0,018 | 0,068 | 827 | 0,989 | $1,79 \times 10^{-8}$ |
| <i>SR</i> | Esférico | 0,017 | 0,068 | 816 | 0,990 | $1,77 \times 10^{-8}$ |
| <i>EVI</i> | Esférico | 0,017 | 0,067 | 815 | 0,990 | $1,77 \times 10^{-8}$ |
| <i>SAVI</i> | Esférico | 0,018 | 0,068 | 827 | 0,989 | $1,79 \times 10^{-8}$ |
| <i>ARVI</i> | Esférico | 0,020 | 0,068 | 843 | 0,990 | $1,73 \times 10^{-8}$ |
| <i>VARI</i> | Esférico | 0,020 | 0,068 | 844 | 0,990 | $1,73 \times 10^{-8}$ |
| <i>CP</i> | Esférico | 0,025 | 0,065 | 942 | 0,977 | $3,20 \times 10^{-8}$ |
| <i>IAF</i> | Esférico | 0,018 | 0,068 | 822 | 0,990 | $1,79 \times 10^{-8}$ |
| <i>Brightness</i> | Esférico | 0,025 | 0,065 | 954 | 0,979 | $3,28 \times 10^{-8}$ |
| <i>Greenness</i> | Esférico | 0,018 | 0,066 | 801 | 0,990 | $1,67 \times 10^{-8}$ |
| <i>Wetness</i> | Esférico | 0,018 | 0,066 | 792 | 0,988 | $1,97 \times 10^{-8}$ |
| <i>G</i> – área basal ($m^2 ha^{-1}$) | | | | | | |
| <i>NDVI</i> | Esférico | 0,008 | 0,033 | 766 | 0,989 | $4,16 \times 10^{-9}$ |
| <i>SR</i> | Esférico | 0,007 | 0,032 | 760 | 0,989 | $4,35 \times 10^{-9}$ |
| <i>EVI</i> | Esférico | 0,007 | 0,032 | 815 | 0,990 | $4,31 \times 10^{-9}$ |
| <i>SAVI</i> | Esférico | 0,008 | 0,033 | 766 | 0,990 | $4,14 \times 10^{-9}$ |
| <i>ARVI</i> | Esférico | 0,009 | 0,033 | 769 | 0,990 | $3,81 \times 10^{-9}$ |
| <i>VARI</i> | Esférico | 0,009 | 0,033 | 771 | 0,990 | $3,79 \times 10^{-9}$ |
| <i>CP</i> | Esférico | 0,011 | 0,031 | 820 | 0,982 | $5,70 \times 10^{-9}$ |
| <i>IAF</i> | Esférico | 0,008 | 0,033 | 763 | 0,989 | $3,95 \times 10^{-9}$ |
| <i>Brightness</i> | Esférico | 0,012 | 0,031 | 828 | 0,981 | $5,80 \times 10^{-9}$ |
| <i>Greenness</i> | Esférico | 0,008 | 0,032 | 737 | 0,990 | $3,85 \times 10^{-9}$ |
| <i>Wetness</i> | Esférico | 0,008 | 0,032 | 720 | 0,989 | $4,19 \times 10^{-9}$ |

Continua...

TABELA 8 – Continuação...

| Covariável | Modelo | C_0 | $C_0 + C$ | a (m) | R^2 | SQDP |
|---|-------------|--------|-----------|---------|-------|------------------------|
| \bar{d} – média aritmética dos diâmetros a 1,3 m do solo (cm) | | | | | | |
| <i>NDVI</i> | Esférico | 0,002 | 0,008 | 914 | 0,951 | $6,33 \times 10^{-10}$ |
| <i>SR</i> | Esférico | 0,0025 | 0,008 | 905 | 0,951 | $6,33 \times 10^{-10}$ |
| <i>EVI</i> | Esférico | 0,0025 | 0,008 | 914 | 0,951 | $6,32 \times 10^{-10}$ |
| <i>SAVI</i> | Esférico | 0,0025 | 0,008 | 914 | 0,951 | $6,33 \times 10^{-10}$ |
| <i>ARVI</i> | Esférico | 0,0026 | 0,008 | 914 | 0,950 | $6,30 \times 10^{-10}$ |
| <i>VARI</i> | Esférico | 0,0026 | 0,008 | 913 | 0,950 | $6,12 \times 10^{-10}$ |
| <i>CP</i> | Esférico | 0,0028 | 0,008 | 917 | 0,949 | $5,84 \times 10^{-10}$ |
| <i>IAF</i> | Esférico | 0,0025 | 0,008 | 914 | 0,951 | $6,33 \times 10^{-10}$ |
| <i>Brightness</i> | Esférico | 0,0028 | 0,008 | 917 | 0,949 | $5,84 \times 10^{-10}$ |
| <i>Greenness</i> | Esférico | 0,0026 | 0,008 | 914 | 0,951 | $6,14 \times 10^{-10}$ |
| <i>Wetness</i> | Esférico | 0,0026 | 0,008 | 913 | 0,952 | $5,94 \times 10^{-10}$ |
| d_g - diâmetro médio quadrático (cm) | | | | | | |
| <i>NDVI</i> | Esférico | 0,004 | 0,010 | 879 | 0,848 | $3,12 \times 10^{-9}$ |
| <i>SR</i> | Esférico | 0,004 | 0,010 | 883 | 0,856 | $2,91 \times 10^{-9}$ |
| <i>EVI</i> | Esférico | 0,004 | 0,010 | 886 | 0,864 | $2,78 \times 10^{-9}$ |
| <i>SAVI</i> | Esférico | 0,004 | 0,010 | 878 | 0,848 | $3,13 \times 10^{-9}$ |
| <i>ARVI</i> | Esférico | 0,004 | 0,010 | 873 | 0,821 | $3,73 \times 10^{-9}$ |
| <i>VARI</i> | Esférico | 0,004 | 0,010 | 872 | 0,822 | $3,78 \times 10^{-9}$ |
| <i>CP</i> | Esférico | 0,004 | 0,010 | 880 | 0,801 | $4,03 \times 10^{-9}$ |
| <i>IAF</i> | Esférico | 0,004 | 0,010 | 881 | 0,854 | $2,99 \times 10^{-9}$ |
| <i>Brightness</i> | Esférico | 0,004 | 0,010 | 887 | 0,801 | $4,03 \times 10^{-9}$ |
| <i>Greenness</i> | Esférico | 0,004 | 0,010 | 873 | 0,810 | $3,84 \times 10^{-9}$ |
| <i>Wetness</i> | Esférico | 0,004 | 0,010 | 875 | 0,806 | $3,92 \times 10^{-9}$ |
| d_{dom} – diâmetro dominante (cm) | | | | | | |
| <i>NDVI</i> | Exponencial | 0,000 | 0,009 | 223 | 0,959 | $4,87 \times 10^{-10}$ |
| <i>SR</i> | Exponencial | 0,000 | 0,009 | 219 | 0,961 | $4,69 \times 10^{-10}$ |
| <i>EVI</i> | Exponencial | 0,000 | 0,009 | 218 | 0,963 | $4,57 \times 10^{-10}$ |
| <i>SAVI</i> | Exponencial | 0,000 | 0,009 | 224 | 0,959 | $4,90 \times 10^{-10}$ |
| <i>ARVI</i> | Exponencial | 0,000 | 0,009 | 229 | 0,955 | $5,11 \times 10^{-10}$ |
| <i>VARI</i> | Exponencial | 0,000 | 0,009 | 229 | 0,955 | $5,03 \times 10^{-10}$ |
| <i>CP</i> | Exponencial | 0,000 | 0,009 | 217 | 0,965 | $3,95 \times 10^{-10}$ |
| <i>IAF</i> | Exponencial | 0,000 | 0,009 | 221 | 0,961 | $4,76 \times 10^{-10}$ |
| <i>Brightness</i> | Exponencial | 0,000 | 0,009 | 217 | 0,965 | $3,93 \times 10^{-10}$ |
| <i>Greenness</i> | Exponencial | 0,000 | 0,009 | 230 | 0,955 | $5,38 \times 10^{-10}$ |
| <i>Wetness</i> | Exponencial | 0,000 | 0,009 | 225 | 0,958 | $5,03 \times 10^{-10}$ |

Continua...

TABELA 8 – Continuação...

| Covariável | Modelo | C_0 | $C_0 + C$ | a (m) | R^2 | SQDP |
|--|----------|-------|-----------|---------|-------|------------------------|
| \bar{h} – média aritmética das alturas (m) | | | | | | |
| <i>NDVI</i> | Esférico | 0,002 | 0,011 | 828 | 0,994 | $2,32 \times 10^{-10}$ |
| <i>SR</i> | Esférico | 0,002 | 0,011 | 820 | 0,993 | $2,50 \times 10^{-10}$ |
| <i>EVI</i> | Esférico | 0,002 | 0,011 | 821 | 0,993 | $2,51 \times 10^{-10}$ |
| <i>SAVI</i> | Esférico | 0,002 | 0,011 | 827 | 0,993 | $2,38 \times 10^{-10}$ |
| <i>ARVI</i> | Esférico | 0,002 | 0,011 | 828 | 0,994 | $2,33 \times 10^{-10}$ |
| <i>VARI</i> | Esférico | 0,002 | 0,011 | 828 | 0,994 | $2,32 \times 10^{-10}$ |
| <i>CP</i> | Esférico | 0,003 | 0,011 | 901 | 0,990 | $3,17 \times 10^{-10}$ |
| <i>IAF</i> | Esférico | 0,002 | 0,011 | 824 | 0,993 | $2,44 \times 10^{-10}$ |
| <i>Brightness</i> | Esférico | 0,003 | 0,011 | 903 | 0,990 | $3,12 \times 10^{-10}$ |
| <i>Greenness</i> | Esférico | 0,002 | 0,011 | 806 | 0,992 | $2,81 \times 10^{-10}$ |
| <i>Wetness</i> | Esférico | 0,002 | 0,011 | 799 | 0,991 | $3,27 \times 10^{-10}$ |
| h_{dom} – altura dominante (m) | | | | | | |
| <i>NDVI</i> | Esférico | 0,002 | 0,009 | 798 | 0,990 | $1,88 \times 10^{-10}$ |
| <i>SR</i> | Esférico | 0,002 | 0,009 | 789 | 0,990 | $2,04 \times 10^{-10}$ |
| <i>EVI</i> | Esférico | 0,002 | 0,009 | 790 | 0,990 | $1,99 \times 10^{-10}$ |
| <i>SAVI</i> | Esférico | 0,002 | 0,009 | 798 | 0,990 | $1,87 \times 10^{-10}$ |
| <i>ARVI</i> | Esférico | 0,002 | 0,009 | 808 | 0,991 | $1,62 \times 10^{-10}$ |
| <i>VARI</i> | Esférico | 0,002 | 0,009 | 809 | 0,991 | $1,67 \times 10^{-10}$ |
| <i>CP</i> | Esférico | 0,003 | 0,009 | 840 | 0,992 | $1,18 \times 10^{-10}$ |
| <i>IAF</i> | Esférico | 0,002 | 0,009 | 794 | 0,990 | $1,96 \times 10^{-10}$ |
| <i>Brightness</i> | Esférico | 0,003 | 0,009 | 841 | 0,992 | $1,16 \times 10^{-10}$ |
| <i>Greenness</i> | Esférico | 0,002 | 0,009 | 774 | 0,992 | $1,35 \times 10^{-10}$ |
| <i>Wetness</i> | Esférico | 0,002 | 0,009 | 765 | 0,992 | $1,39 \times 10^{-10}$ |

Observação: As linhas destacadas indicam as covariáveis seleccionadas.

FONTE: O autor (2020).

Houve predominância de ajuste com o modelo Esférico, exceto para a variável diâmetro dominante (d_{dom}) com o modelo Exponencial (TABELA 8). Esses ajustes também resultaram em valores baixos de efeito pepita (C_0), evidenciando a qualidade das modelagens. Além disso, os valores de alcance (a) foram semelhantes aos obtidos via krigagens simples e ordinárias, com pequenas oscilações entre as covariáveis para uma mesma variável do povoamento.

Com base também nas estimativas do parâmetro alcance (a), evidenciou-se menores valores para as variáveis volume do povoamento (V), área basal (G), média

aritmética das alturas (\bar{h}) e altura dominante (h_{dom}) com a covariável *Wetness* (TABELA 8). Isso demonstra a influência dessa medida, a qual está relacionada como um indicador de umidade (PHUA; SAITO, 2003), na dependência espacial de povoamentos florestais. Por outro lado, a covariável *Brightness*, expressa como um índice de brilho do solo (ZANOTTA et al., 2019), resultou nos maiores valores de alcance (TABELA 8), indicando o seu efeito nas correlações espaciais entre as unidades amostrais.

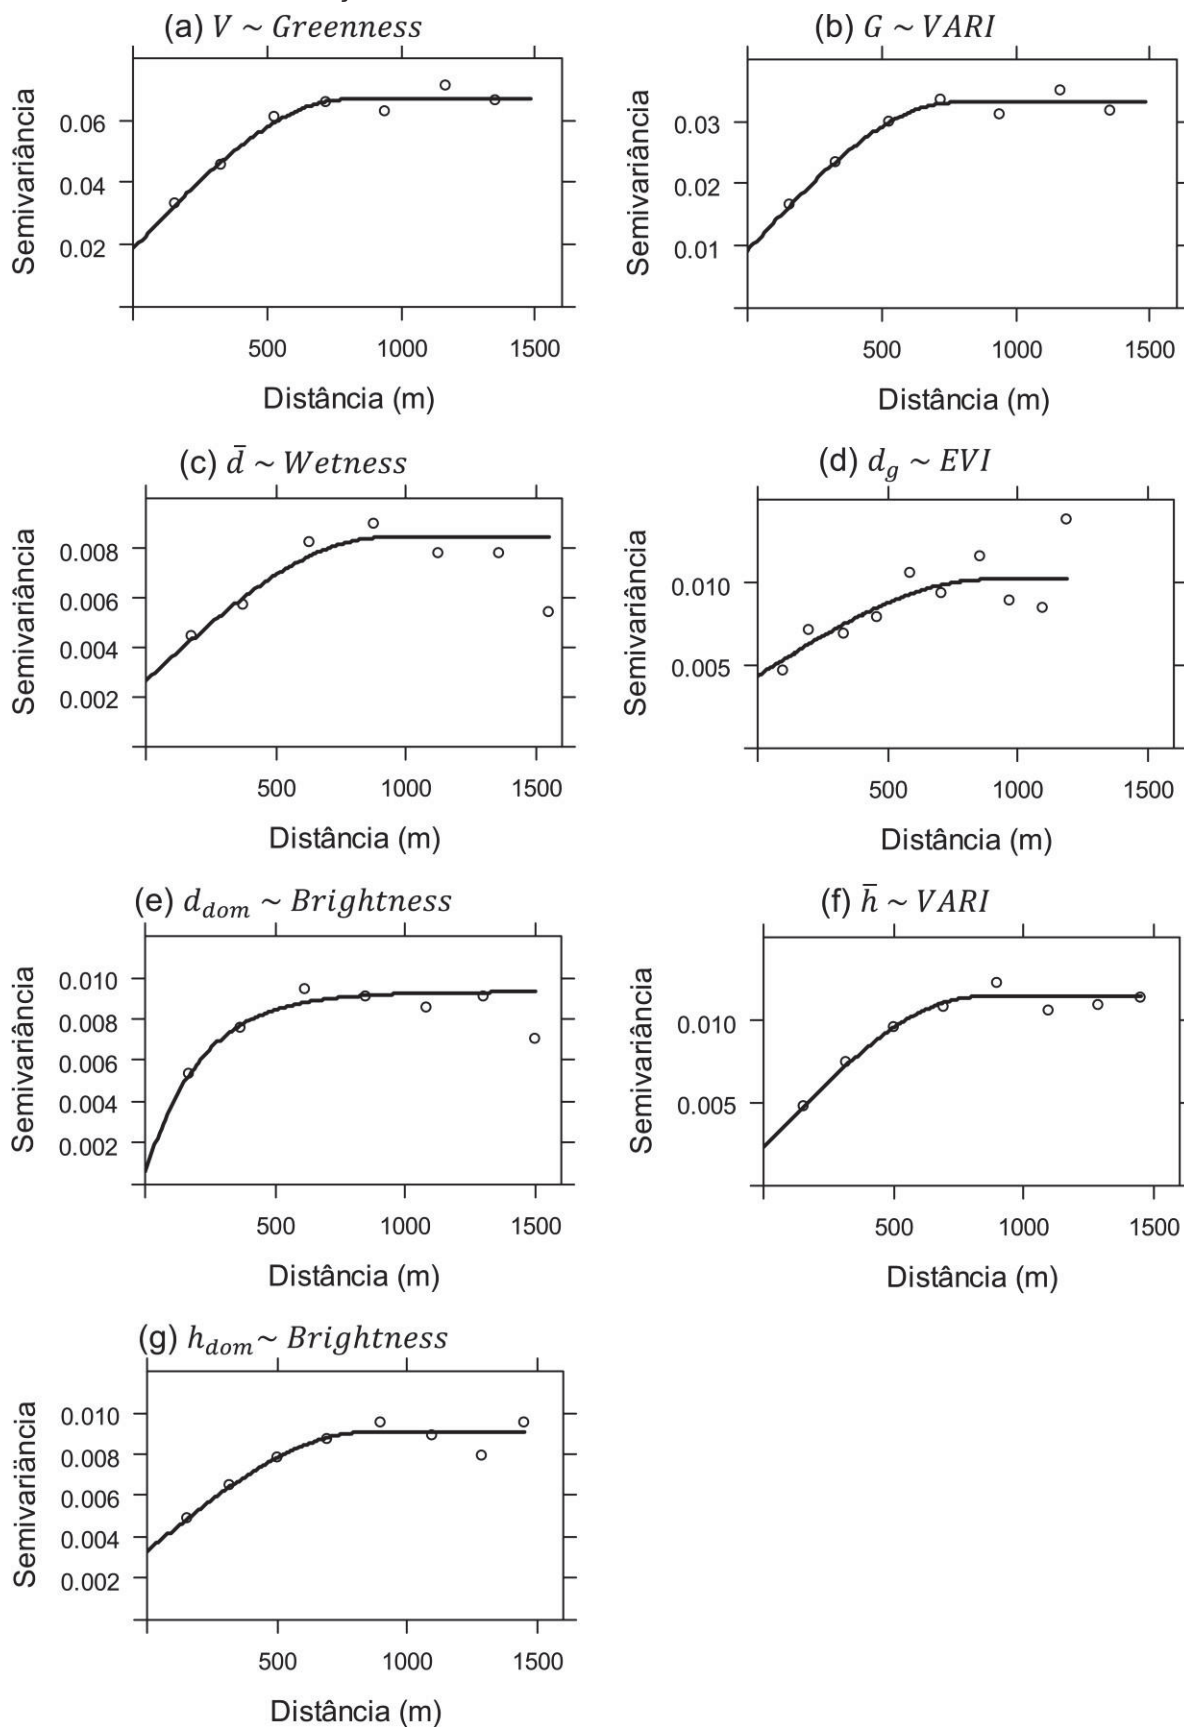
Os melhores semivariogramas ajustados para as variáveis do povoamento com as respectivas covariáveis de sensoriamento remoto (TABELA 8) foram selecionados com base nos maiores coeficientes de determinação (R^2) e nas menores somas de quadrados dos desvios ponderados (SQDP). Assim, para a variável volume do povoamento (V), a covariável *Greenness* resultou no melhor ajuste, que, embora tenha apresentado R^2 igual a 0,99 e semelhante às outras covariáveis, acarretou na menor SQDP de $1,67 \times 10^{-8}$.

As variáveis área basal (G) e média aritmética das alturas (\bar{h}) apresentaram melhor desempenho com o índice *VARI*, resultando nos menores valores de SQDP de $3,79 \times 10^{-9}$ e $2,32 \times 10^{-10}$, respectivamente. Para a variável média aritmética dos diâmetros (\bar{d}), a covariável *Wetness* apresentou o maior R^2 de 0,9522 e a menor SQDP igual a $5,94 \times 10^{-10}$.

A variável diâmetro médio quadrático (d_g) obteve melhor desempenho com o índice *EVI*, com o maior R^2 de 0,8640 e a menor SQDP de $2,78 \times 10^{-9}$. Ademais, para as variáveis diâmetro dominante (h_{dom}) e altura dominante (h_{dom}), a covariável *Brightness* possibilitou os maiores valores de R^2 , respectivamente iguais a 0,9656 e 0,9925, bem como as menores SQDP de $3,93 \times 10^{-10}$ e $1,16 \times 10^{-10}$.

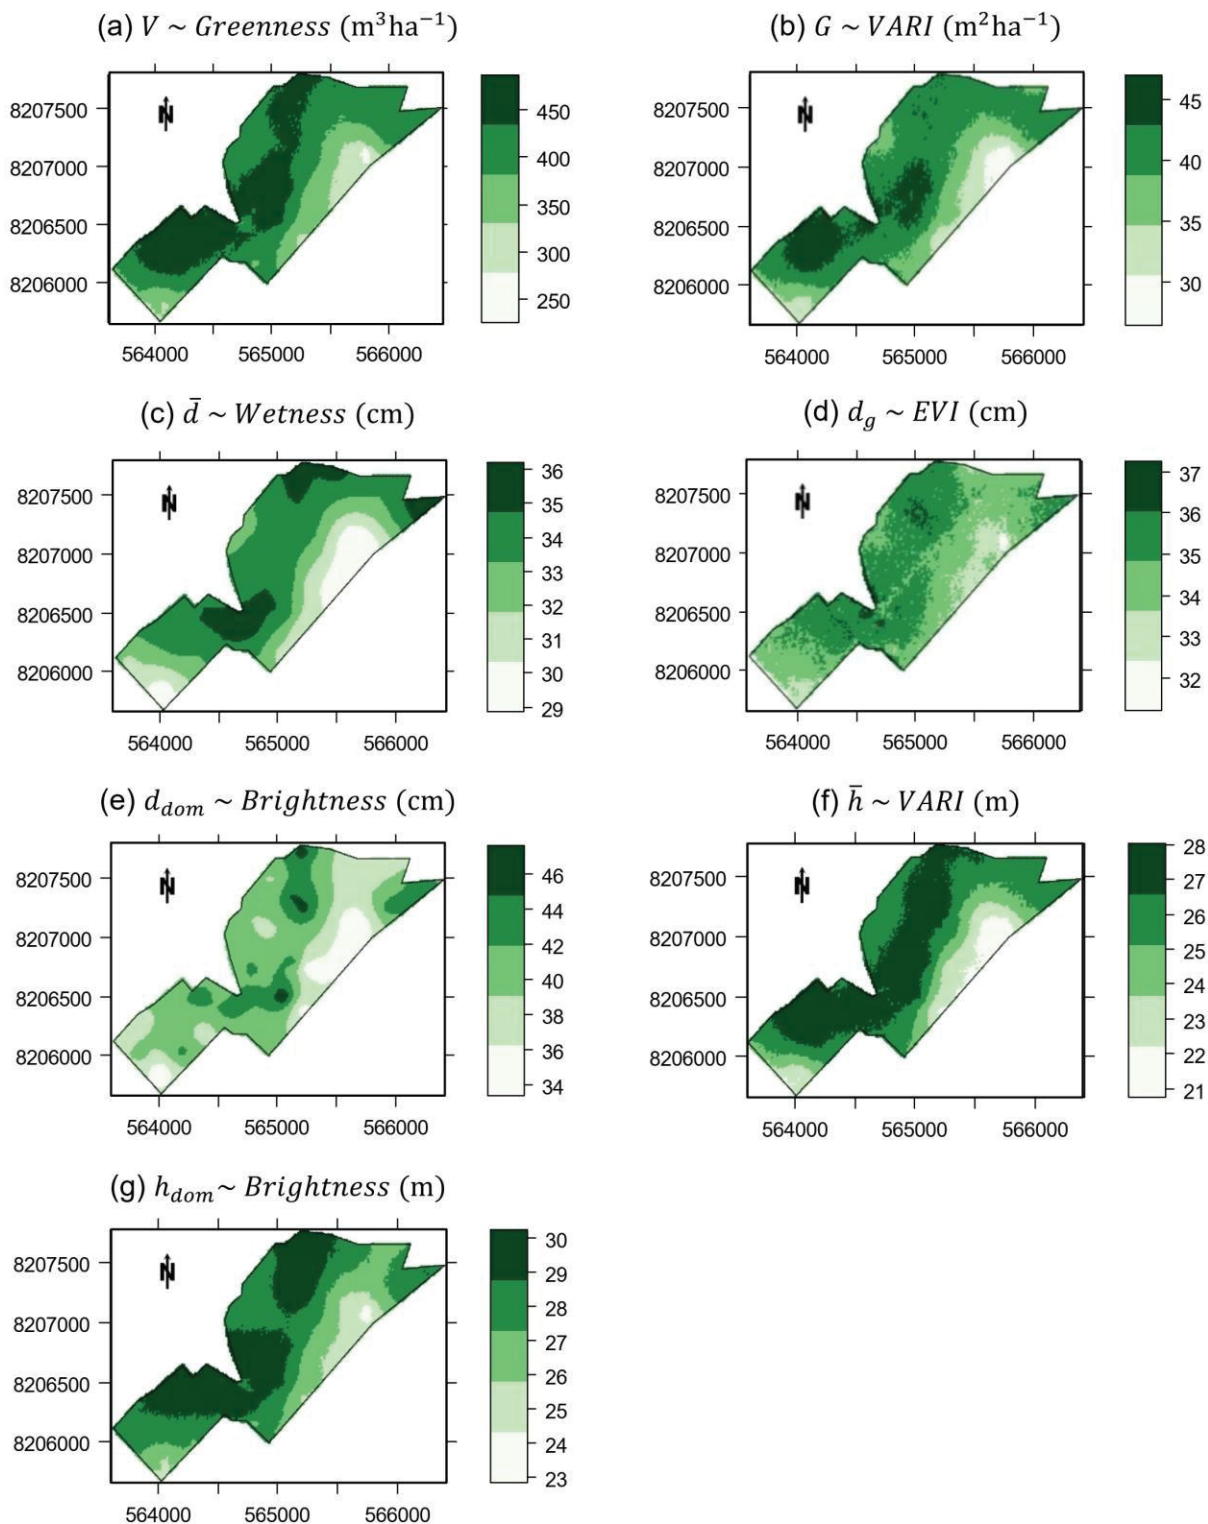
Os semivariogramas ajustados em função das covariáveis de sensoriamento remoto de melhor desempenho estatístico na krigagem com deriva externa apresentaram padrões adequados, ou seja, com o comportamento crescente e posteriormente estabilizador das semivariâncias estimadas (FIGURA 12). Com isso, eles foram empregados para a elaboração dos mapas temáticos (FIGURA 13).

FIGURA 12 – SEMIVARIOGRAMAS AJUSTADOS PARA AS VARIÁVEIS DO POVOAMENTO DE TECA EM FUNÇÃO DE COVARIÁVEIS DE SENSORIAMENTO REMOTO.



FONTE: O autor (2020).

FIGURA 13 – DISTRIBUIÇÃO ESPACIAL DAS VARIÁVEIS DO POVOAMENTO DE TECA POR KRIGAGEM COM DERIVA EXTERNA.



FONTE: O autor (2020).

Os padrões espaciais verificados pelas krigagens simples e ordinária podem também ser observados na krigagem com deriva externa (KDE), em que a região central apresentou os valores maiores para as variáveis do povoamento, enquanto a

região Leste exibiu valores menores (FIGURA 13). Porém, a KDE propiciou nível maior de detalhamento dos padrões espaciais dessas variáveis, especialmente nos locais não amostrados.

A relação espacial entre a variável volume do povoamento (V) e a covariável *Greenness* (FIGURA 13a) pode ser explicada por esse índice representar a vegetação verde e sadia, correlacionado com o percentual de biomassa (ZANOTTA et al., 2019). A área basal (G), que representa o grau de ocupação do terreno pela floresta (MACHADO; FIGUEIREDO FILHO, 2006), e a variável média aritmética das alturas (\bar{h}) obtiveram melhor desempenho com o índice *VARI* (FIGURA 13f).

A média aritmética dos diâmetros (\bar{d}) apresentou melhor relação espacial com a covariável *Wetness* (FIGURA 13c), que representa a umidade do solo e da planta (PHUA; SAITO, 2003). O diâmetro médio quadrático (d_g), que corresponde aos diâmetros das árvores de área transversal média, cujos valores mais se aproximam das árvores de volume médio do povoamento (MACHADO; FIGUEIREDO FILHO, 2006), apresentou relação espacial com a covariável *EVI* (FIGURA 13d). Esse resultado pode ser explicado pela maior sensibilidade desse índice às mudanças estruturais do dossel da floresta (JENSEN, 2009; ZANOTTA et al., 2019).

As variáveis diâmetro dominante (d_{dom}) e altura dominante (h_{dom}) apresentaram melhor desempenho com a covariável *Brightness*, que expressa diferenças nas características do solo, como a distribuição e o tamanho das partículas, e é normalmente associada aos solos nus ou parcialmente cobertos (CRIST; CICONE, 1984). Como *Brightness* evidencia a ausência parcial ou total de vegetação sob o solo, os menores valores dessa covariável tendem a expressar os locais com maior ocupação do terreno e, conseqüentemente, de maior dominância das árvores, evidenciando também suas correlações negativas (FIGURA 6).

4.8 AVALIAÇÃO DOS MÉTODOS DE KRIGAGEM

As estatísticas de validação cruzada obtidas pela krigagem simples e ordinária, e krigagem com deriva externa com a covariável de sensoriamento remoto selecionada para as estimativas das variáveis do povoamento, estão apresentadas na TABELA 8.

TABELA 8 - ESTATÍSTICA DA VALIDAÇÃO CRUZADA DOS MÉTODOS DE KRIGAGEM PARA ESTIMATIVA DAS VARIÁVEIS DO POVOAMENTO DE TECA.

| Método | Covariável | BIAS | MAE | MPE | RMSE | RMSE% | r_{xx} |
|---|-------------------|---------|--------|-------|-------|-------|----------|
| <i>V</i> – volume do povoamento ($\text{m}^3 \text{ha}^{-1}$) | | | | | | | |
| Krigagem simples | | -0,0101 | 0,137 | 2,31% | 0,206 | 3,46% | 0,532 |
| Krigagem ordinária | | -0,0035 | 0,139 | 2,32% | 0,206 | 3,46% | 0,531 |
| Krigagem com deriva externa | <i>Greenness</i> | 0,0048 | 0,148 | 2,48% | 0,228 | 3,83% | 0,430 |
| <i>G</i> – área basal ($\text{m}^2 \text{ha}^{-1}$) | | | | | | | |
| Krigagem simples | | -0,0075 | 0,099 | 2,71% | 0,147 | 4,03% | 0,501 |
| Krigagem ordinária | | -0,0027 | 0,100 | 2,73% | 0,148 | 4,03% | 0,499 |
| Krigagem com deriva externa | <i>VARI</i> | -0,0028 | 0,104 | 2,84% | 0,150 | 4,09% | 0,480 |
| \bar{d} – média aritmética dos diâmetros a 1,3 m do solo (cm) | | | | | | | |
| Krigagem simples | | -0,0014 | 0,056 | 1,59% | 0,071 | 2,03% | 0,548 |
| Krigagem ordinária | | -0,0002 | 0,056 | 1,60% | 0,071 | 2,05% | 0,539 |
| Krigagem com deriva externa | <i>Wetness</i> | 0,0013 | 0,057 | 1,65% | 0,073 | 2,11% | 0,501 |
| d_g - diâmetro médio quadrático (cm) | | | | | | | |
| Krigagem simples | | -0,0031 | 0,066 | 1,88% | 0,090 | 2,55% | 0,340 |
| Krigagem ordinária | | -0,0007 | 0,067 | 1,90% | 0,090 | 2,56% | 0,329 |
| Krigagem com deriva externa | <i>EVI</i> | -0,0005 | 0,067 | 1,90% | 0,089 | 2,51% | 0,379 |
| d_{dom} – diâmetro dominante (cm) | | | | | | | |
| Krigagem simples | | -0,0016 | 0,0641 | 1,74% | 0,086 | 2,37% | 0,330 |
| Krigagem ordinária | | -0,0006 | 0,0644 | 1,75% | 0,087 | 2,38% | 0,317 |
| Krigagem com deriva externa | <i>Brightness</i> | -0,0002 | 0,0655 | 1,78% | 0,088 | 2,40% | 0,292 |
| \bar{h} – média aritmética das alturas (m) | | | | | | | |
| Krigagem simples | | -0,0035 | 0,052 | 1,62% | 0,076 | 2,35% | 0,628 |
| Krigagem ordinária | | -0,0011 | 0,053 | 1,64% | 0,076 | 2,34% | 0,629 |
| Krigagem com deriva externa | <i>VARI</i> | 0,0013 | 0,058 | 1,75% | 0,076 | 2,38% | 0,613 |
| h_{dom} – altura dominante (m) | | | | | | | |
| Krigagem simples | | -0,0025 | 0,057 | 1,72% | 0,076 | 2,31% | 0,517 |
| Krigagem ordinária | | -0,0009 | 0,058 | 1,74% | 0,076 | 2,32% | 0,512 |
| Krigagem com deriva externa | <i>Brightness</i> | 0,0007 | 0,061 | 1,83% | 0,080 | 2,41% | 0,450 |

BIAS = viés; *MAE* = erro médio absoluto; *MPE* = erro médio em porcentagem; *RMSE* = raiz quadrada do erro médio quadrático absoluto; *RMSE%* = raiz quadrada do erro médio quadrático em porcentagem; e r_{xx} = correlação linear entre os valores observados e estimados.

FONTE: O autor (2020).

As estatísticas da validação cruzada pelo método de krigagem simples

apresentaram valores semelhantes ou iguais à krigagem ordinária (TABELA 8). Entretanto, os valores do viés (*BIAS*) foram maiores, indicando que esse interpolador geoestatísticos gerou tendências maiores nas estimativas. Com isso, a krigagem simples tendeu a superestimar os valores das variáveis do povoamento nas unidades amostrais, comparativamente à krigagem ordinária.

Contudo, apesar de pouco explorada nas Ciência Florestais, a krigagem simples possibilitou gerar predições com valores baixos para os erros médios de estimação, bem como semelhantes à krigagem ordinária (TABELA 8). Isso foi evidenciado especialmente pelas medidas de erro médio em porcentagem (*MPE*) e raiz quadrada do erro médio quadrático em porcentagem (*RMSE%*). Assim, é possível afirmar que as médias amostrais das variáveis do povoamento representaram uma informação representativa da população no interpolador espacial.

Para o método de krigagem com deriva externa, apenas para a variável diâmetro médio quadrático (d_g) as estatísticas de validação foram melhores que os outros métodos de krigagem (TABELA 8). Isso indicou que a utilização de uma covariável nas estimativas dessa variável gerou estimativas mais próximas à realidade.

Embora as estimativas das variáveis do povoamento nas unidades amostrais não tenham, de modo geral, apresentado em estatísticas de validação cruzada superiores às krigagens simples e ordinária (TABELA 8), e com a krigagem com deriva externa foi possível gerar mapas temáticos com maior nível de detalhamento (FIGURA 13), garantindo erros médios com valores baixos. Esses resultados são os desejados quando se almeja aplicar o manejo de precisão em povoamentos comerciais, uma vez que também possibilitam estimações adequadas em locais não medidos.

5 CONCLUSÕES

As variáveis de sensoriamento remoto apresentam fraca correlação numérica e dependência linear com as variáveis do povoamento de teca. Isso tende a inviabilizar o uso delas como covariáveis nas modelagens geoestatísticas, especialmente por meio da cokrigagem ordinária.

A krigagem com deriva externa proporciona predições dos padrões espaciais com maior nível de detalhes das variáveis do povoamento, o que resulta em minimização de possíveis erros de suavização gerados pelos métodos tradicionais de krigagem simples e ordinária. Isso proporciona também recomendações mais precisas de intervenções localizadas ao manejo de plantios de teca.

A integração de variáveis de sensoriamento remoto ao inventário florestal por meio da geoestatística é vantajosa, uma vez que o produto das estimativas por krigagem com deriva externa pode ser utilizado como uma informação auxiliar. Além disso, essa integração possibilita também o aumento da confiabilidade dos inventários florestais sem elevação dos custos decorrentes com a maior intensidade amostral em campo.

REFERÊNCIAS

- ABRAF - ASSOCIAÇÃO BRASILEIRA DE PRODUTORES DE FLORESTAS PLANTADAS. **Anuário estatístico da ABRAF 2013, ano base 2012**. Brasília: ABRAF, 2013. 142 p.
- AHMED, O.S.; FRANKLIN, S.E.; WULDER, M.A.; WHITE, J.C. Characterizing stand-level forest canopy cover and height using Landsat time series, samples of airborne LiDAR, and the Random Forest algorithm. **Journal of Photogrammetry and Remote Sensing**, v. 101, p.89-101, 2015.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES GONÇALVES, J. L.; SPAROVEK, G. Koppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2014.
- ANDRIOTTI, J. L. S. **Fundamentos de estatística e geoestatística**. São Leopoldo: UNISINOS, 2003. 165 p.
- ASSMANN, E. **The principles of forest yield study: studies in the organic production, structure, increment, and yield of forest stands**. Oxford: Pergamon Press, 1970. 506 p.
- BAGNARA, D.; PRIETTO, P. D. M.; TIMBOLA, R. S. **Aplicação da krigagem ordinária na modelagem do pH e da dureza da água subterrânea na área central de Passo Fundo – RS**. Teoria e Prática na Engenharia Civil, n. 20, p.15-22, 2012.
- BAIG, M. H. A.; ZHANG, L.; SHUAI, T.; TONG, Q. Derivation of tasseled cap transformation based on Landsat 8 at-satellite reflectance. **Remote Sensing Letters**, v. 5, n. 5, p. 423-431, 2014.
- BENITEZ, F. L.; ANDERSON, L. O.; FORMAGGIO, A. R. Evaluation of geostatistical techniques to estimate the spatial distribution of aboveground biomass in the Amazon rainforest using high-resolution remote sensing data. **Acta Amazonica**, v. 46, n. 2, p.55-62, 2016.
- BERTERRETCHÉ, M.; HUDAK, A. T.; COHEN, W. B.; MAIERSPERGER, T. K.; GOWER, S. T.; DUNGAN, J. Comparison of regression and geostatistical methods for mapping leaf area index (LAI) with Landsat ETM+ data over a boreal forest. **Remote Sensing of Environment**, v. 96, p. 46-61, 2005.
- BIRTH, G. S.; McVEY, G. Measuring the color of growing turf with a reflectance spectrophotometer. **Agronomy Journal**, v. 60, p. 640-643, 1968.
- BOGNOLA, I. A.; RIBEIRO JÚNIOR, P. J.; Alves da SILVA, E. A.; LINGNAU, C.; HIGA, A. R. Modelagem uni e bivariada da variabilidade espacial de rendimento de *Pinus taeda* L. **Floresta**, v. 38, n. 2, p. 373-385, 2008.
- BOYD, D. S.; DANSON, F. M. Satellite remote sensing of forest resources: Three decades of research development. **Progress in Physical Geography**, v. 29, p. 1-26,

2005.

BUDDENBAUM, H.; SCHLERF, M.; HILL, J. Classification of coniferous tree species and age classes using hyperspectral data and geostatistical methods. **International Journal of Remote Sensing**, v. 26, n. 24, p. 5453-5465, 2005.

CALDEIRA, S. F.; OLIVEIRA, D. L. C. Desbaste seletivo em povoamentos de *Tectona grandis* com diferentes idades. **Acta Amazonica**, v. 38, n. 2, p. 223-228, 2008.

CALIXTO, A. Z.; PELISSARI, A. L.; ROVEDA, M.; NAKAJIMA, N. Y. Modelagem geoestatística dos sortimentos volumétricos em povoamentos de *Pinus* sp. **Agrarian Academy**, v. 4, n. 7, p.335-345, 2017.

CAMPOS, J. C. C.; LEITE, H. G. **Mensuração Florestal**: perguntas e respostas. 5 ed. Viçosa: Editora UFV, 2017. 636 p.

CARRASCO, P. C. Nugget effect, artificial or natural? **The Journal of The Southern African Institute of Mining and Metallurgy**, v. 110, p. 299-305, 2010.

CARVALHO, M. P.; MENDONÇA, V. Z.; PEREIRA, F. C. B. L.; ARF, M. V.; KAPPES, C. Produtividade de madeira do eucalipto correlacionada com atributos do solo visando ao mapeamento de zonas específicas de manejo. **Ciência Rural**, v. 42, n. 10, p. 1797-1803, 2012.

CENTENO, J. A. S. **Sensoriamento remoto e processamento de imagens digitais**. Curitiba: Curso de Pós-Graduação em Ciências Geodésicas, 2004. 219 p.

CIGAGNA, C.; BONOTTO, D. M.; STURARO, J. R.; CAMARGO, A. F. M. Geostatistical techniques applied to mapping limnological variables and quantify the uncertainty associated with estimates. **Acta Limnologica Brasiliensia**, v. 27, n. 4, p. 421-430, 2015.

CORONA, P. Integration of forest mapping and inventory to support forest management. **iForest - Biogeosciences and Forestry**, v. 3, n. 3, p. 59-64, 2010.

CRIST, E. P.; CICONE, R. C.; A physically-based transformation of thematic mapper data – the TM tasseled cap. **IEE Transactions on Geoscience and Remote Sensing**, v. 22, n. 3, p. 256-263, 1984.

DEB, J. C.; PHINN, S.; BUTT, N.; MCALPINE, C. A. 2017. Climatic-induced shifts in the distribution of teak (*Tectona grandis*) in tropical Asia: Implications for forest management and planning. **Environmental Management**, v. 60, p. 422-435, 2017.

DUCHEMIN, B.; HADRIA, R.; ERRAKI, S.; BOULET, G.; MAISONGRANDE, P.; CHEHBOUNI, A.; ESCADAFAL, R.; EZZAHAR, J.; HOEDJES; J.C.B.; KHARROU, M.H.; KHABBA, S.; MOUGENOT, B.; OLIOSO, A.; RODRIGUEZ, J.C.; SIMONNEAUX, V. Monitoring wheat phenology and irrigation in Central Morocco: On the use of relationships between evapotranspiration, crops coefficients, leaf area index and remotely-sensed vegetation indices.

Agricultural Water Management, v. 79, p.1-27, 2006.

DRESCHER, R.; GAVA, F. H.; PELISSARI, A. L.; ACOSTA, F. C.; SILVA, V. S. M. Equações volumétricas para *Tectona grandis* Linn F. em povoamentos jovens no estado de Mato Grosso. **Advances in Forestry Science**, v. 1, n. 2, p. 65-70, 2014.

ENVI – EXELIS VISUAL INFORMATION SOLUTIONS. **A quick start to ENVI 5**. Harris Corporation, 2015. 12 p. Disponível em: <<https://www.harrisgeospatial.com/portals/0/pdfs/envi/QuickStartENVI5.pdf>>. Acessado em: 12 dez. 2019.

ESRI – ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE. **ArcGIS Professional GIS for desktop, v. 10.4**. ESRI, 2016.

FITZ, P. R. **Geoprocessamento sem complicação**. São Paulo: Oficina de textos, 2008. 160 p.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. São Paulo: Oficina de textos, 2011. 128 p.

GATES, D.M.; KEEGAN, J.; WEIDNER, V.R. Spectral properties of plants. **Applied Optics**, v. 4, n. 1, p. 11-20, 1965.

GEORGAKARAKOS, S.; KITSIOU, D. Mapping abundance distribution of small pelagic species applying hydroacoustic and co-kriging techniques. **Hydrobiologia**, v. 612, n. 1, p. 155-169, 2008.

GIL, R. L.; LANSSANOVA, L.R.; CHIG, L.A.; GARRET, A. T. A. de.; RIBEIRO, V. O. de.; FILHO, P. C. O. de.; FERREIRA, K. R. Modelling spatial variability of soil chemical attributes in *Tectona grandis* stands in central-west Brazil. **Journal of Tropical Forest Science**, v. 30, n. 3, p. 376-383, 2018.

GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing Environment**, v. 80, n. 1, p. 76-87, 2002.

GUEDES, I. C. L.; MELLO, J. M.; MELLO, C. R.; OLIVEIRA, A. D.; SILVA, S. T.; SCOLFORO, J. R. S. Técnicas geoestatísticas e interpoladores espaciais na estratificação de povoamentos de *Eucalyptus* sp. **Ciência Florestal**, v. 22, n. 3, p. 541-550, 2012.

GUYOT, G. **Optical Properties of vegetation canopies – applications of Remote Sensing in Agriculture**. France: Editora Butterworths. 1990. 427 p.

HERNÁNDEZ-STEFANONI, J. L.; GALLARDO-CRUZ, J. A.; MEAVE, J. A.; DUPUY, J. M. Combining geostatistical models and remotely sensed data to improve tropical tree richness mapping. **Ecological Indicators**, v. 11, n. 5, p. 1046-1056, 2011.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing Environment**, v. 25, p. 295-309, 1988.

HUETE, A. R.; LIU, H. Q. An error of sensitivity analysis of the atmospheric and soil-correcting variants of the NDVI for the MODIS-EOS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 32, n. 4, p. 897-905, 1994.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; LEEUWEN, W. J van. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing Environment**, v. 59, p. 440-451, 1997.

HUSCH, B.; BEERS, T. W.; KERSHAW, J. A. **Forest mensuration**. 4.ed. New York: J. Wiley, 2003. 443 p.

IBÁ – INSTITUTO BRASILEIRO DE ÁRVORES. **Anuário estatístico do IBÁ 2019, ano base 2018**. Brasília: IBÁ, 2019. 80 p.

JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. São José dos Campos. 2009. 672 p.

JORDAN, C. F. Derivation of leaf area index from quality of light on the forest floor. **Ecology**, v. 50, n. 4, p. 663-666, 1969.

KANEVSKI, M.; MAIGNAN, M. **Analysis and modelling of spatial environmental data**. Lausanne: EPFL Press, 2004. 288 p.

KARAHAN, G.; ERŞAHİN, S. Geostatistics in characterizing spatial variability of forest ecosystems. **Eurasscience Journals**, v. 6, n. 1, p. 9-22, 2018.

KAUFMAN, Y. J.; TANRE, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 261-270, 1992.

KOLLERT, W.; KLEINE, M. **The global teak study analysis, evaluation and future potential of teak resources**. Vienna: International Union of Forest Research Organizations (IUFRO), 2017. 108 p.

KNIPLING, E. B. Physical and physiological basis for the reflectance visible and near infrared radiation from vegetation. **Remote Sensing of Environment**, v. 1, n. 3. p. 155-159, 1970.

LANDIM, P. M. B. Sobre Geoestatística e mapas. **Terra e Didática**, v. 2, n. 1, p. 19-33, 2006.

LEAL, F. A.; MATRICARDI, E. A. T.; MIGUEL, E. P. Interpolador geoestatístico para estimar volume num povoamento de *Eucalyptus urophylla*, em Rio Verde/Goiás, Nucleus, v. 11, n. 1, p. 153-160, 2014.

LILLESAND, T. M.; KIEFER, R. W. **Remote Sensing and image interpretation**. 3. ed. New York: John Wiley & Sons, 1994. 750 p.

LIMA, C. G. R.; CARVALHO, M. P.; NARIMATSU, K. C. P.; SILVA, M. G.; QUEIROZ, H. A. Atributos físico-químicos de um latossolo do cerrado brasileiro e sua relação

com características dendrométricas do eucalipto. **Revista Brasileira de Ciência do Solo**, v. 34, p. 163-173, 2010.

MACHADO, S. A.; FIGUEIREDO FILHO, A. **Dendrometria**. 2. ed. Guarapuava: Unicentro, 2006. 316 p.

MASELLJ, F.; CHIESI, M. Evaluation of statistical methods to estimate forest volume in a Mediterranean region. **IEEE Transactions on Geoscience and Remote Sensing**, v. 44, n. 8, p. 2239-2250, 2006.

MATÉRN, B. **Spatial variation**. Estocolmo: Meddelanden fran Statens Skogsforsknings Institut, 1960. 144 p.

MATHERON, G. **The theory of regionalized variables and its applications**. Fontainebleau: École Nationale Supérieure des Mines de Paris, 1971. 211 p.

MENESES, P. R.; ALMEIDA, T.; BAPTISTA, G. M. M. **Reflectância dos materiais terrestres: análise e interpretação**. São Paulo: Oficina de Textos, 2019, 334 p.

MENG, Q.; CIESZEWSKI, C.; MADDEN, M. Large area forest inventory using Landsat ETM+: A geostatistical approach. **Journal of Photogrammetry and Remote Sensing**, v. 64, p. 27-36, 2009.

MIGUEL, E. P.; REZENDE, A. V.; LEAL, F. A.; MATRICARDI, E. A. T.; VALE, A. T.; PEREIRA, R. S. Redes neurais artificiais para a modelagem do volume de madeira e biomassa do cerradão com dados de satélite. **Pesquisa Agropecuária Brasileira**, v. 50, n. 9, p. 829-839, 2015.

MIRANDA, I.; SOUSA, V.; PEREIRA, H. 2011. Wood properties of teak (*Tectona grandis*) from a mature unmanaged stand in East Timor. **Journal of Wood Science**, v. 57, p. 171-178, 2011.

MOITA NETO, J. M.; MOITA, G. C. Uma introdução à análise exploratória de dados multivariados. **Química Nova**, v. 21, n. 4, p. 467-469, 1998.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4 ed. Viçosa: UFV, 2011. 422p.

MUTANGA, O.; RUGEGE, D. Integrating remote sensing and spatial statistics to model biomass distribution in a tropical savanna. **International Journal of Remote Sensing**, v. 27, n. 16, p. 3499-3514, 2006.

NOGUEIRA, G. S.; LEITE, H. G.; CAMPOS, J. C. C.; TAKIZAWA, F. H.; COUTO, L. Avaliação de um modelo de distribuição diamétrica ajustado para povoamentos de *Tectona grandis* submetidos a desbaste. **Revista Árvore**, v. 30, n. 3, p. 377-387, 2006.

NOVO, E. M. M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Blucher, 2010. 387 p.

- OLIVER, M. A.; WEBSTER, R. A tutorial guide to geostatistics: Computing and modelling variograms and kriging. **CATENA**, v. 113, p. 56-69, 2014.
- OLIVEIRA, E. B.; MACHADO, S. A.; FILHO, A. F. Sistema para simulação do crescimento e da produção de *Pinus taeda* L. e avaliação econômica de regimes de manejo. **Revista Árvore**, v. 22, n. 1, p. 99-111, 1998.
- OLIVEIRA, I. M.S de.; SILVEIRA, E. M. O.; PAIVA L. de.; JÚNIOR, F. W. A.; MELLO, J. M. de. Remote Sensing and Geostatistics Applied to Post-stratification of Eucalyptus Stands. **Floresta e Ambiente**, v. 25, n. 3, 2018.
- PASSOS, C. A. M.; BUFULIN, L.; GONÇALVES, M. R. Avaliação silvicultural de *Tectona grandis* L.f em Cáceres – MT. **Ciência Florestal**, v. 16, n. 2, p. 225-232, 2006.
- PEBESMA, E. J. Multivariable geostatistics in S: the gstat package. **Computers & Geosciences**, v. 30, n. 7, p. 683-691, 2004.
- PÉLLICO NETO, S.; BRENA, D. A. **Inventário florestal**. Curitiba: Editorado pelos autores, 1997. 316 p.
- PELISSARI, A.L. **Silvicultura de precisão aplicada ao desenvolvimento de *Tectona grandis* L.f. na região sul do estado de mato grosso**. 2012. 81 f. Dissertação (Mestrado em Ciências Florestais e Ambientais) – Universidade Federal de Mato Grosso, Pós-Graduação em Ciências Florestais e Ambientais, Cuiabá, 2012a.
- PELISSARI, A. L.; CALDEIRA, S. F.; DRESCHER, R.; SANTOS, V. S. Modelagem geoestatística da dinâmica espacial da altura dominante de *Tectona grandis* L.f. (teca). **Enciclopédia Biosfera**, v. 8, p. 1249-1260, 2012b.
- PELISSARI, A. L.; GUIMARÃES, P. P.; BEHLING, A.; EBLING, A. A. Cultivo da teca: características da espécie para implantação e condução de povoamentos florestais. **Agrarian Academy**, v. 1, n. 01, p. 127-145, 2014a.
- PELISSARI, A. L.; FIGUEIREDO FILHO, A.; CALDEIRA, S. F.; MACHADO, S. A. Geoestatística aplicada ao manejo de povoamentos florestais de teca, períodos de pré-desbaste seletivo, no estado do Mato Grosso. **Revista Brasileira de Biometria**, v. 32, n. 3, p. 430-444, 2014b.
- PELISSARI, A. L. **Geoestatística aplicada ao manejo de povoamentos de *Tectona grandis* L. f.** 2015. 119 f. Tese (doutorado) - Universidade Federal do Paraná, Programa de Pós-Graduação em Engenharia Florestal, Curitiba, 2015.
- PELISSARI, A. L. Geostatistical modeling of timber volume spatial variability for *Tectona grandis* L. f. precision forestry. **Cerne**, v. 23, n. 1, p. 115-122, 2017.
- PONZONI, F.J. Comportamento espectral da vegetação. In.: MENESSES, R.; MADEIRA NETTO, J.S. **Sensoriamento remoto: refletância dos alvos naturais**. Brasília: UnB, Planaltina: Embrapa Cerrados. p.157-199. 2001.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. São Paulo: Oficina de Textos, 2012. 160 p.

PHUA, M.; SAITO, H. Estimation of biomass of a mountainous tropical forest using Landsat TM data. **Canadian Journal of Remote Sensing**, v. 29, n. 4, p. 429-440, 2003.

QGIS DEVELOPMENT TEAM. **QGIS Geographic Information System**. Open Source Geospatial Foundation Project, 2019. Disponível em: <<http://qgis.osgeo.org>>.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna. 2018.

REIS, A. A.; MELLO, J. M.; RAIMUNDO, M. R.; JÚNIOR, F. W. A.; OLIVEIRA, M. S.; DINIZ, J. M. F. S. Estratificação de um povoamento de eucalipto por interpoladores geoestatísticos e sensoriamento remoto. **Pesquisa agropecuária Brasileira**, v. 51, n. 10, p. 1751-1761, 2016.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Remote Sensing**, v. 43, p. 1541-1552, 1977.

ROCHA, C. H. B. **Geoprocessamento: tecnologia transdisciplinar**. Juiz de Fora: Ed. Autor, 2000. 220 p.

ROUSE, J. W.; HAAS, R. H.; SHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS-1. **Anais... III Earth Resources Technology Satellite-1 Symposium**, v. 1, NASA Scientific and Technical Information Office, Washington, v. 1, p. 309-317, 1974.

ROVEDA, M.; FIGUEIREDO FILHO, A.; PELISSARI, A. L.; SANTOS, M. M. Spatial continuity in a Mixed Ombrophilous Forest with different size and shape of sample units. **Cerne**, v. 22, n. 2, p. 189-196, 2016.

ROVEDA, M.; FILHO, A. F.; PELISSARI, A. L.; GENÚ, A. M.; GRESPAN, T. Modelagem da Continuidade e da dinâmica espacial da área basal em classes diamétricas de um remanescente de floresta ombrófila mista. **Revista Brasileira Biomass**, v. 36, n. 1, p. 74-88, 2018.

SALES, M. H.; SOUZA, C. M.; KYRIAKIDIS, P. C.; ROBERTS, D. A.; VIDAL, E. Improving spatial distribution estimation of forest biomass with geostatistics: a case study for Rondonia, Brazil. **Ecological Modeling**, v. 205, p. 221-230, 2007.

SAMRA, J. S.; GILL, H. S.; BHATIA, V. K. Spatial stochastic modelling of growth and forest resource evaluation. **Forest Science**, v. 35, n. 3, p. 663-676, 1989.

SANTOS, M. C, dos.; ROVEDA, M.; ZANON, M. L. B.; FILHO, A. F.; ROIK, M.; PACHECO, J. M.; SCAVINSKI, V. Inventário florestal utilizando técnicas de silvicultura de precisão em povoamentos de *Eucalyptus grandis* Hill ex Maiden.

Floresta e Ambiente, v. 24, 2017.

SANTOS, H. G. dos.; JACOMINE, P. K. T.; ANJOS, L. H. C. dos.; OLIVEIRA, V. A. de.; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A. de.; ARAUJO FILHO, J. C. de.; OLIVEIRA, J. B. de.; CUNHA, T. J. F. Sistema Brasileiro de Classificação de Solos, Brasília, DF: EMBRAPA, 2018, 353 p.

SANQUETTA, C. R.; CORTE, A. P. D.; RODRIGUES, A. L.; WATZLAWICK, L. F. **Inventários Florestais: Planejamento e Execução**. Curitiba: Multi-Graphic Gráfica e Editora, 2014.

SCHOBER, P.; BOER, C.; SCHWARTE, L. A. Correlation coefficients: Appropriate use and interpretation. **Anesthesia & Analgesia**, v. 126, n. 5, p. 1763-1768, 2018.

SILVA E. L. S.; PONZONI, F. J. Comparação entre a reflectância hemisférica de folhas e a reflectância bidirecional de um dossel. **Revista Árvore**, v. 19, n. 4, p. 466-478, 1995.

SILVA, S. T. **Estratificação da fitofisionomia cerrado para inventário florestal utilizando geotecnologia**. 2009. 84 f. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Programa de Pós-Graduação em Engenharia Florestal, Lavras, 2009.

SILVA, R. S. da.; VENDRUSCOLO, D. G. S.; ROCHA, J. R. M. da.; CHAVES, A. G. S.; SOUZA, H. S.; MOTTA, A. S. da. Desempenho silvicultural de *Tectona grandis* L. f. em diferentes espaçamentos em Cáceres, MT. **Floresta e Ambiente**, v. 23, n. 3, p. 397-405, 2016.

SOUZA, C. C.; MOREIRA, A. A.; SCHIMITH, R. S.; BRANDÃO, P. C.; SILVA, E. Técnicas de sensoriamento remoto como subsídios aos estudos de florestas implantadas no Brasil - uma revisão bibliográfica. **Ciência Florestal**, v. 17, p. 409-417, 2007.

TEWARI, V. P.; SINGH, B. A first-approximation simple dynamic growth model for forest teak plantations in Gujarat state of India. **Southern Forests: A Journal of Forest Science**, v. 80, n. 1, p. 59-65, 2018.

TUOMINEN, S.; FISH, S.; POSO, S. Combining remote sensing, data from earlier inventories, and geostatistical interpolation in multisource forest inventory. **Canadian Journal of Forest Research**, v. 33, n. 4, p. 624-634, 2003.

USGS – UNITED STATES GEOLOGICAL SURVEY. **Earth Explorer. Landsat 8**. 2019. Disponível em: <<https://earthexplorer.usgs.gov/>>. Acesso em: 04 jun. 2019.

VIEIRA, S. R. Uso de geoestatística em estudos de variabilidade espacial de propriedades do solo. In: NOVAIS, R. F.; ALVAREZ, V. H.; SCHAEFER, C. E. G. R. (Org.). **Tópicos em ciência do solo**. Viçosa: Sociedade Brasileira de Ciência do Solo, v. 1, p. 01-54, 2000.

VIDAL, C.; LANZ, A.; TOMPPA, E.; SCHADAUER, K.; GSCHWANTNER, T.; COSMO, L. Di.; ROBERT, N. Establishing forest inventory reference definitions for forest and growing stock: a study towards common reporting. **Silva Fennica**, v. 42, n. 2, p. 247-266, 2008.

YADAV, B. K. V.; NANDY, S. Mapping aboveground woody biomass using forest inventory, remote sensing and geostatistical techniques. **Environmental Monitoring and Assessment**, v. 187, n. 308, 2015.

YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística: conceitos e aplicações**. São Paulo: Oficina de textos, 2013. 215 p.

WATANABE, J.; YAMAMOTO, J. K.; ROCHA, M. M.; FONSECA, P. P. Estudo da influência da correlação inicial entre variáveis nos resultados de co-estimativas. **Geociências**, v. 28, n. 4, p. 467-484, 2009.

WACKERNAGEL, H. **Multivariate Geostatistics**. Springer, Berlin, 1995. 256 p.

WEBSTER, R.; OLIVER, M. A. **Geostatistics for environmental scientists**. 2. ed. West Sussex: John Wiley & Sons Ltd, 2007. 333 p.

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite**. São Paulo: Oficina de Textos, 2019. 320 p.

ZHANG, C.; FRANKLIN, S. E.; WULDER, M. A. Geostatistical and texture analysis of airborne-acquired images used in forest classification. **International Journal of Remote Sensing**, v. 25, n. 4, p. 859-865, 2004.

APÊNDICE 1 – APLICAÇÃO DOS MÉTODOS DE KRIGAGEM EM R

A seguir, um estudo dirigido da aplicação dos métodos de krigagem é demonstrado no ambiente computacional R para predição de variáveis dendrométricas de um povoamento de *Tectona grandis*. As duas primeiras etapas são aplicáveis em todos os métodos de krigagem.

1) ETAPA 1: INSTALAÇÃO DOS PACOTES

Primeiramente, o diretório de trabalho é definido, seguido pela instalação e carregamento dos pacotes necessários para a realização da modelagem geoestatística.

```
>setwd() #inserir endereço da pasta de trabalho
>install.packages("gstat") #instalar pacote
>library(gstat) #chamar pacote
>install.packages("sp") #pacote 'sp': classes and methods for spatial data
>library(sp)
>install.packages("spData") #pacote
>install.packages("RColorBrewer")
>library(RColorBrewer)
>install.packages("classInt")
>library(classInt)
```

2) ETAPA 2: BASE DE DADOS E CONFIGURAÇÕES ADICIONAIS

```
Dados<-read.csv2('DADOS_PARCELAS.csv', h = T) #dados de variáveis do povoamento
covar2 <-read.csv2 ('GREEN.csv', h = T) #covariável
borda <- read.table('borda.txt', h = T, dec = ',') #limite da área de estudo
grid <- read.table('grid.txt', h = T, dec = ',') #dados do grid para krigagem
```

Para a modelagem geoestatística, é necessário converter os dados em *Spatial points data frame* para a utilização do pacote *gstat*.

```
>coordinates(dados) = ~x+y
```

```
>class(dados)
coordinates(covar2) = ~x+y
class(covar2)
```

Configurações adicionais para os mapas temáticos:

Limite da área:

```
limite <- read.table('borda.txt', h = T, dec = ',') # limites da área
limite <- Polygon(limite, hole = T) # Converter em polígono
limite <- list("sp.polygons", limite, border = "black", lwd = 2.5) # Inserir o polígono em uma lista
```

Flecha Norte:

```
arrow <- list("SpatialPolygonsRescale", layout.north.arrow(), offset = c(564000, 8207000), scale = 500)
```

Barra de escala:

```
scalebar <- list("SpatialPolygonsRescale", layout.scale.bar(height=0.05), scale = 800, fill =
c("transparent", "black"), offset = c(565400, 8205850))
text1 = list("sp.text", c(565400, 8205800), "0")
text2 = list("sp.text", c(566250, 8205800), "800 m")
```

Mapas temáticos - definir a cor:

```
if(!require(RColorBrewer)){
  install.packages("RColorBrewer")
  library(RColorBrewer)}
display.brewer.all() # Selecionei 'Greens'
```

Definir a quantidade de classes:

```
if(!require(classInt)){
  install.packages("classInt")
  library(classInt)}
breaks.qt.G <- classIntervals(G.btt, n = 5, style = "equal", intervalClosure = "right")
```

3) ETAPA 3: MODELAGEM E PREDIÇÃO

a) KRIGAGEM SIMPLES

Ajuste dos semivariogramas experimental e teórico para a variável volume:

```
>V.vgm <- variogram(log(V)~1, data = dados, cutoff = 1500, width = 210)
>V.fit <- vgm(nugget = 0.02030, psill = 0.06810-0.02030, range = 824, model = "Sph")
>V.fit <- fit.variogram(V.vgm, V.fit, fit.kappa = F)
>plot (V.vgm, V.fit, pch = 1, lwd = 2, col = 'black', ylab = 'Semivariância',
      xlab = 'Distância (m)', ylim = c(0,0.08), xlim=c(0,1600))
```

Estatísticas de qualidade do ajuste:

```
>SSErr_V <- attr(V.fit, "SSErr") #soma dos quadrados dos desvios ponderados
>weig_V <- V.vgm$np/V.vgm$dist^2 #pesos
>SStot_V <- sum(weig_V*(V.vgm$gamma-mean(V.vgm$gamma))^2) # Soma de quadrados total
>R2_V <- 1-(SSErr_V/SStot_V) # coeficiente de determinação
```

Validação cruzada por *Leave-one-out*:

```
>V.cv <- krige.cv(log(V)~1, dados, grid, model = V.fit, beta = mean(log(dados$V)), nfold = nrow(dados))
>BIAS_V <- mean(V.cv$residual) # viés
>MAE_V <- mean(abs(V.cv$residual)) #erro médio absoluto
>MPE_V <- MAE_V/mean(V.cv$observed) *100 # erro médio em porcentagem
>RMSE_V <- sqrt(mean(V.cv$residual^2)) #raiz quadrada do erro médio quadrático
>RMSE100_V <- RMSE_V/mean(V.cv$observed) *100 # RMSE em porcentagem
>CORREL_V <- cor(V.cv$observed, V.cv$var1.pred) ## Correlação entre valores observados e
estimados.
```

Interpolação espacial:

```
>grid <- read.table('grid.txt', h = T, dec = ',') # Dados do grid para krigagem
>gridded(grid) <- ~x+y # converter o objeto em "SpatialPixels"
>class(grid)

>V.krige <- krige(log(V)~1, dados, grid, model = V.fit, beta = mean(log(dados$V)))
>V.bt <- exp(V.krige@data$var1.pred) # backtransformed
# ...thus make another correction to remove kriging bias in sample mean
>V.btt <- V.bt * (mean(dados$V)/mean(V.bt)) # correct backtransformed vals
>V.krige@data$var1.pred <- V.btt # overwrite w/ correct vals
```

```

>names(V.kriged) <- c("Prediction", "variance")
>breaks.qt.V <- classIntervals(V.btt, n = 5, style = "equal", intervalClosure = "right")
>spplot(V.kriged, "Prediction", scales = list(draw = T), main = 'Krigagem simples - Volume',
  key.space = 'right', col = "black",
  col.regions = brewer.pal(n = 9, name = "Greens"),
  par.settings = list(fontsize = list(text = 14)),
  at = breaks.qt.V$brks,
  sp.layout = list(limite, arrow),
  contour = T,
  labels = F)

```

b) KRIGAGEM ORDINÁRIA

Ajuste dos semivariogramas experimental e teórico para a variável volume:

```

>V.vgm <- variogram(log(V)~1, data = dados, cutoff = 1500, width = 210)
>V.fit <- vgm(nugget = 0.02030, psill = 0.06810-0.02030, range = 824, model = "Sph")
>V.fit <- fit.variogram(V.vgm, V.fit, fit.kappa = F)
>plot(V.vgm, V.fit, pch = 1, lwd = 2, col = 'black', ylab = 'Semivariância', xlab = 'Distância (m)',
ylim =c(0,0.08), xlim=c(0,1600))

```

Estatísticas de qualidade do ajuste:

```

>SSErr_V <- attr(V.fit, "SSErr") #soma dos quadrados dos desvios ponderados
>weig_V <- V.vgm$np/V.vgm$dist^2 #pesos
>SStot_V <- sum(weig_V*(V.vgm$gamma-mean(V.vgm$gamma))^2) # Soma de quadrados total
>R2_V <- 1-(SSErr_V/SStot_V) # coeficiente de determinação

```

Validação cruzada por *Leave-one-out*:

```

>V.cv <- krige.cv(log(V)~1, dados, grid, model = V.fit, nfold = nrow(dados))
>BIAS_V <- mean(V.cv$residual) # Viés
>MAE_V <- mean(abs(V.cv$residual)) # Erro médio absoluto
MPE_V <- MAE_V/mean(V.cv$observed)*100 # Erro médio em porcentagem
>RMSE_V <- sqrt(mean(V.cv$residual^2)) # Raiz quadrada do erro médio quadrático
>RMSE100_V <- RMSE_V/mean(V.cv$observed)*100 # RMSE em porcentagem
>CORREL_V <- cor(V.cv$observed, V.cv$var1.pred) # Correlação entre valores observados e
estimados

```

Interpolação espacial

```

>grid <- read.table('grid.txt', h = T, dec = ',') # Dados do grid para krigagem

```

```

>gridded(grid) <- ~x+y # converter o objeto em "SpatialPixels"
>class(grid)

>V.krige <- krige(log(V)~1, dados, grid, model = V.fit)
>V.bt <- exp(V.krige@data$var1.pred) # backtransformed
# ...thus make another correction to remove kriging bias in sample mean
>V.btt <- V.bt * (mean(dados$V)/mean(V.bt))      # correct backtransformed vals
>V.krige@data$var1.pred <- V.btt                  # overwrite w/ correct vals
>names(V.krige) <- c("Prediction", "variance")
>breaks.qt.V <- classIntervals(V.btt, n = 5, style = "equal", intervalClosure = "right")
>spplot(V.krige, "Prediction", scales = list(draw = T), main = 'Krigagem ordinária - Volume',
  key.space = 'right', col = "black",
  col.regions = brewer.pal(n = 9, name = "Greens"),
  par.settings = list(fontsize = list(text = 14)),
  at = breaks.qt.V$brks,
  sp.layout = list(limite, arrow),
  contour = T,
  labels = F)

```

c) COKRIGAGEM ORDINÁRIA

Ajuste dos semivariogramas experimental e teórico para a variável volume:

```

>V.vgm <- variogram(log(V)~1, data = dados, cutoff = 620, width = 90)
>V.fit <- fit.variogram(V.vgm, vgm(psill = 700, model = c("Nug", "Sph", "Exp", "Gau", "Mat", "Pen", "Cir"),
range = 600, nugget = 50, anis = F), fit.kappa = F)
>V.fit # retorna o melhor ajuste
>plot(V.vgm, V.fit, pch = 1, lwd = 2, col = 'black', ylab = 'Semivariância', xlab = 'Distância (m)')

```

Ajuste semivariograma experimental e teórico para a covariável:

```

>GREEN.vgm <- variograma (GREEN~1, data = dados, cutoff = 620, width = 90)
>GREEN.fit <- fit.variogram (GREEN.vgm, vgm(psill = 1, model = "Gau", range = V.fit$range),
fit.ranges= F)
# Usar o mesmo modelo para a variável principal - limitação do pacote gstat
# Usar o mesmo alcance (range) para a variável principal - limitação do pacote gstat
# Não permite que altere o valor do alcance
>plot(GREEN.vgm, GREEN.fit, pch = 1, lwd = 2, col = 'black', ylab = 'Semivariância', xlab =
'Distância(m)', ylim = c(0,20), xlim=c(0,700))

```

Ajuste semivariograma cruzado:

```
>V_GREEN <- gstat(NULL, id = "Volume", form = log(V) ~ 1, data = dados) # Semivariograma para
variável principal
>V_GREEN <- gstat(V_GREEN, id = "GREEN", form = GREEN ~ 1, data = dados) # Semivariograma
para covariável
>plot(variogram(V_GREEN, cutoff = 620, width = 90))
```

Ajuste dos semivariogramas teóricos:

```
>V_GREEN <- gstat(V_GREEN, id = "Volume", model = GREEN.fit) # Variável principal
>V_GREEN <- gstat(V_GREEN, id = "GREEN", model = GREEN.fit) # Covariável
>print(V_GREEN) #parâmetros dos ajustes
```

Ajuste do semivariograma cruzado

```
>V_GREEN <- gstat(V_GREEN, id = c("Volume","GREEN"), model = vgm(psill = 1, model = "Gau",
range = V_GREEN$model$`Volume`$range))
# Usar o mesmo modelo para a variável principal - limitação do pacote gstat
# Usar o mesmo alcance (range) para a variável principal - limitação do pacote gstat
>v.cross <- variogram(V_GREEN, cutoff = 620, width = 90) # Semivariograma cruzado experimental
>V_GREEN <- fit.lmc(v.cross, V_GREEN, fit.lmc = T, correct.diagonal = 1.0) # ajuste do
semivariograma cruzado - Usar 'correct.diagonal = 1.01' quando problemas forem encontrados na
cokrigagem
>print(V_GREEN) # Parâmetros dos ajustes
>plot(v.cross, V_GREEN$model, ylab = 'Semivariância', xlab = 'Distância (m)', col = 'black')
>plot(v.cross[v.cross$id == 'Volume.GREEN',], V_GREEN$model[[3]], ylab = 'Semivariância', xlab =
'Distância (m)', col = 'black')
```

d) KRIGAGEM COM DERIVA EXTERNA

```
>model.V <- as.formula('log(V) ~ GREEN')
>ajust.V <- lm(model.V, dados)
>summary(ajust.V)
```

Ajuste de semivariogramas experimental e teórico:

```
>V.vgm <- variogram(model.V, data = dados, cutoff = 1500, width = 210)
>V.fit <- vgm(nugget = 0.02030, psill = 0.06810-0.02030, range = 824, model = "Sph")
>V.fit <- fit.variogram(V.vgm, V.fit, fit.kappa = F)
>plot(V.vgm, V.fit, pch = 1, lwd = 2, col = 'black', ylab = 'Semivariância', xlab = 'Distância (m)',
ylim = c(0,0.08), xlim=c(0,1600))
```

Estatísticas de qualidade do ajuste:

```
>SSErr_V <- attr(V.fit, "SSErr") #soma dos quadrados dos desvios ponderados
>weig_V <- V.vgm$np/V.vgm$dist^2 #pesos
>SStot_V <- sum(weig_V*(V.vgm$gamma-mean(V.vgm$gamma))^2) #soma de quadrados total
>R2_V <- 1-(SSErr_V/SStot_V) #coeficiente de determinação
```

Validação cruzada por *Leave-one-out*:

```
>V.cv <- krige.cv(model.V, dados, covar2, model = V.fit, nfold = nrow(dados))
>BIAS_V <- mean(V.cv$residual) # viés
>MAE_V <- mean(abs(V.cv$residual)) # erro médio absoluto
>MPE_V <- MAE_V/mean(V.cv$observed)*100 # erro médio em porcentagem
>RMSE_V <- sqrt(mean(V.cv$residual^2)) # raiz quadrada do erro médio quadrático
>RMSE100_V <- RMSE_V/mean(V.cv$observed)*100 # RMSE em porcentagem
>CORREL_V <- cor(V.cv$observed, V.cv$var1.pred) # correlação entre valores observados e
estimados
```

Interpolação espacial:

```
>V.kriged <- krige(model.V, dados, covar2, model = V.fit)
>V.bt <- exp(V.kriged@data$var1.pred) # backtransformed
# ...thus make another correction to remove kriging bias in sample mean
>V.btt <- V.bt * (mean(dados$V)/mean(V.bt)) # correct backtransformed vals
>V.kriged@data$var1.pred <- V.btt # overwrite w/ correct vals
>names(V.kriged) <- c("Prediction", "variance")
>breaks.qt.V <- classIntervals(V.btt, n = 5, style = "equal", intervalClosure = "right")
>spplot(V.kriged, "Prediction", scales = list(draw = T), main = 'Krigagem com Deriva Externa - Volume',
  key.space = 'right', col = "black",
  col.regions = brewer.pal(n = 9, name = "Greens"),
  par.settings = list(fontsize = list(text = 14)),
  at = breaks.qt.V$brks,
  sp.layout = list(limite, arrow),
  contour = T,
  labels = F)
```